



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학박사 학위논문

레이더 표적에 관한 최적의 산란점 추출 및 식별

Optimal Scattering Center Extraction and
Identification in Radar Target

2020년 8월

서울대학교 대학원

전기·정보공학부

정 상 훈

레이더 표적에 관한 최적의 산란점 추출 및 식별

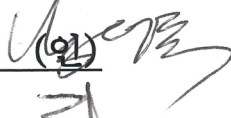




Optimal Scattering Center Extraction and
Identification in Radar Target

지도 교수 정 현 교

이 논문을 공학박사 학위논문으로 제출함
2020년 8월

서울대학교 대학원
전기·정보공학부
정 상 훈

정상훈의 박사 학위논문을 인준함
2020년 8월

위원장	남 상 욱	(인) 
부위원장	정 현 교	(인) 
위원	오 정 석	(인) 
위원	정 용 식	(인) 
위원	강 노 원	(인) 

초 록

본 논문에서는 레이더 표적 식별에서 식별 성능에 가장 큰 영향을 주는 특징점 추출 단계에 사용되는 데이터로 표적의 산란점 (Scattering Center) 정보를 사용하는 것을 제안하였으며, 공대공 탐지와 같은 제한된 측정 데이터만 얻을 수 있는 환경에서도 원본 데이터와 유사하게 복원할 수 있는 압축 센싱 (CS : Compressive Sensing)과 설계 변수가 많은 문제를 잘 해결할 수 있는 고차원 최적화 (High-dimensional Optimization) 알고리즘을 사용하여 기존의 산란점 추출 기법보다 더 정확하며 연산 속도의 저하를 줄일 수 있는 산란점 추출 알고리즘을 제안하였다. 이에 대한 검증을 위해 수치해석적 방법을 통해 얻어진 원시 데이터에 대한 식별 성능을 확인하였으며, 실제 측정 실험을 통해 검증을 수행하였다.

먼저 표적 식별에 사용되는 레이더 수신 신호를 획득하는 과정과 모델링에 대해 설명하였으며, 다음으로 본 논문에서 제시하는 최적의 산란점 추출 알고리즘의 기반이 되는 CS 알고리즘과 고차원 최적화 알고리즘에 대한 구체적인 원리를 설명하였다. 기존의 CS 알고리즘 중 하나인 orthogonal matching pursuit (OMP) 알고리즘에서 연산 속도를 향상시킨 새로운 OMP 알고리즘을 제시하고 간단한 산란점 추출 문제에 적용하여 기존의 OMP보다 81.2%의 연산 시간을 줄이면서 동일한 산란점 정보를 추출하는 것을 확인하였다. 다음으로 본 논문에서 해결하려는 산란점 추출과 같이 설계 변수가 많은 고차원 최적화 문제의 경우에 강점을 보이는 혼합 유전 알고리즘 (Hybrid Genetic Algorithm)을 제시하였다. 나선형 교차 방식을 선택하여 고차원 문제를 잘 풀 수 있도록 하였으며, 최적 해를 잘 찾으며 수렴 속도를 증가시키기 위해 해 집단을 여러 그룹으로 나누어 각 그룹 별로 다른 교차 방식을 수행하였다. 그에 대한 검증을 위해 여러 시험 함수와 산란점 추출 문제에 적용하였으며 기존의 최적화 알고리즘과의 비교를 수행하여 제안한 알고리즘이 고차원 문제를 해결하는데 가장

뛰어남을 보였다.

최적의 산란점을 추출하기 위해 앞서 제시한 향상된 OMP 알고리즘과 혼합 유전 알고리즘을 결합하였다. 먼저 레이더 수신 신호에 향상된 OMP 알고리즘을 적용하여 산란점을 추출하였다. 추출된 산란점 정보를 초기값으로 하여 혼합 유전 알고리즘을 적용하여 보다 정확한 산란점 정보를 추출하였으며, 혼합 유전 알고리즘의 단점인 연산 시간의 증가를 64.87% 줄일 수 있었다.

획득한 산란점 정보를 이용하여 표적 식별을 수행하였는데, 식별기로 최적화가 가능한 서포트 벡터 머신 (SVM : Support Vector Machine)을 이용하였다. 검증을 위해 시뮬레이션 데이터와 실제 측정 데이터에 앞서 제시한 최적의 산란점 추출 기법을 적용하고, 최적화된 SVM을 이용한 식별 성능을 확인해 보았다. 그 결과, 3개의 관측 방위각과 같이 적은 측정 데이터에도 높은 식별 성공률을 보임을 확인할 수 있었으며, SNR 20dB의 잡음 환경에서도 성공적으로 식별됨을 확인하였다.

식별 수행에서 획득할 수 있는 표적의 관측각은 제한적이며, 획득한 산란점 정보의 정확성도 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 알고리즘을 적용하면 보다 정확하게 표적을 식별하는데 도움이 될 것으로 보인다.

주요어 : 압축 센싱 (Compressive Sensing), 산란점 추출 (Extraction of Scattering Center), 특징점 추출 (Feature Extraction), 고차원 최적화 (High-dimensional Optimization), 서포트벡터머신 (Support Vector Machine), 표적 식별 (Target Identification).

학 번 : 2014-22578

목 차

국문 초록	i
목 차	iii
그림 목차	v
표 목차	vii
기호 및 약어 설명	viii
제 1 장 서 론	1
1.1 연구의 배경	1
1.2 논문 구성	8
제 2 장 레이더 수신 신호 모델링	10
2.1 수신 신호 모델링	10
2.2 시뮬레이션 결과	13
제 3 장 최적의 산란점 추출 알고리즘	15
3.1 Compressive sensing 기반의 산란점 추출 알고리즘	15
3.1.1 Compressive sensing	15
3.1.2 향상된 CS 알고리즘	18
3.1.3 시뮬레이션 결과	20
3.2 최적화 알고리즘 기반의 산란점 추출	28
3.2.1 혼합 유전 알고리즘	29
3.2.2 시뮬레이션 결과	36
제 4 장 최적의 산란점 추출 및 식별	44
4.1 최적의 산란점 추출 기법	44
4.1.1 산란점 추출 기법	47
4.1.2 시뮬레이션 결과	51
4.2 식별 알고리즘	57
4.2.1 식별기 연구	57
4.2.2 Support vector machine을 이용한 식별	58
4.3 시뮬레이션 및 실험 결과	71
4.3.1 시뮬레이션 결과	71
4.3.2 측정 실험 결과	76
제 5 장 결론 및 향후 연구 계획	95
5.1 결론	95
5.2 향후 연구계획	97
참고문헌	98
Abstract	106

그림 목차

그림 1.1. 레이더 수신 신호.....	1
그림 1.2. 표적 식별 단계.....	2
그림 1.3. 고각, 방위각, 주파수 별로 획득한 RCS 데이터베이스	3
그림 1.4. 압축 센싱의 개념도.....	4
그림 2.1. 첩 신호.....	10
그림 2.2. 산란점의 위치.....	14
그림 2.3. 거리 프로파일.....	14
그림 3.1. OMP 알고리즘의 순서도.....	18
그림 3.2. 향상된 OMP 알고리즘의 순서도.....	19
그림 3.3. 시간 영역에서의 신호 x	20
그림 3.4. 10%의 무작위 샘플링된 신호,.....	21
그림 3.5. 향상된 OMP 알고리즘으로 획득한 성진 신호 s 의 크기	21
그림 3.6. 산란점 위치와 관측점 위치.....	24
그림 3.7. (a) 추출된 산란점(향상된 OMP) (b) 추출된 산란점 (OMP).....	25
그림 3.8. (a) 추출된 이미지(BPA, 12개의 임의의 관측 방위각) (b) 추출된 이미지(BPA, $\phi = 0 \sim 359^\circ$).....	26
그림 3.9. 유전 알고리즘의 순서도.....	29
그림 3.10. 나선형 교차.....	31
그림 3.11. 혼합 유전 알고리즘의 자식 해 생성 방법.....	34
그림 3.12. 혼합 유전 알고리즘의 순서도.....	35
그림 3.13. 혼합 유전 알고리즘의 평가를 위한 시험 함수.....	38
그림 3.14. 'A' 형태의 표적.....	41
그림 3.15. (a) WOA로 추정된 산란점 (b) BMO로 추정된 산란점 (c) 제안한 혼합 유전 알고리즘으로 추정된 산란점..	42
그림 3.16. (a) 'A' 형태의 표적 (b) 추정된 산란점 (c) 'O' 형태의 표적 (d) 추정된 산란점 (e) 'F' 형태의 표적 (f) 추정된 산란점.....	43
그림 4.1. (a) 표적의 산란점(향상된 OMP, $L=6$) (b) 표적의 산란점(향상된 OMP, $L=4$) (c) 표적의 산란점 (향상된 OMP, $L=3$).....	46
그림 4.2. 최적의 산란점 추출 기법.....	48
그림 4.3. 최적의 산란점 결과 (a) 향상된 OMP+최적화(5세대 후) (b) 향상된 OMP+최적화.....	49
그림 4.4. (a) 수렴 곡선(임의의 초기해) (b) 수렴 곡선(향상된 OMP로 얻은 초기해).....	50

그림 4.5. (a) A-380 카드 모델 (b) 유로파이터 카드 모델 (c) F-15 카드 모델.....	51
그림 4.6. (a) A-380 HRRP (b) 유로파이터 HRRP (c) F-15 HRRP.....	53
그림 4.7. (a) A-380의 복원된 영상 (b) 유로파이터의 복원된 영상 (c) F-15의 복원된 영상.....	54
그림 4.8. 추출된 산란점(향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	55
그림 4.9. 추출된 산란점(향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	56
그림 4.10. 초평면에 의한 분류.....	59
그림 4.11. 초평면 선택.....	60
그림 4.12. 비선형 SVM.....	62
그림 4.13. 식별 표적 (a) 표적 1(제트 스키) (b) 표적 2(선박) (c) 표적 3(잠망경).....	64
그림 4.14. 표적 DB (a) 표적 1 (b) 표적 2 (c) 표적 3.....	65
그림 4.15. SNR에 따른 식별 결과 (a) k-NN (b) Bayes (c) SVM.....	67
그림 4.16. PCA, LDA의 최적화.....	68
그림 4.17. 커널 함수 최적화.....	70
그림 4.18. 수렴 곡선.....	72
그림 4.19. 추출된 특징점(PCA).....	73
그림 4.20. 추출된 특징점(PCA+LDA).....	73
그림 4.21. 식별 결과(시뮬레이션).....	74
그림 4.22. 잡음에 따른 식별 성공률.....	75
그림 4.23. 레이더 측정 시스템.....	77
그림 4.24. 로테이터.....	77
그림 4.25. 측정 표적 (a) A-380 (b) Eurofighter (c) F-15.....	78
그림 4.26. 측정 표적의 HRRP (a) A-380 (b) Eurofighter (c) F-15.....	79
그림 4.27. A-380 (a) 실제 표적 (b) SAR 영상.....	81
그림 4.28. Eurofighter (a) 실제 표적 (b) SAR 영상.....	82
그림 4.29. F-15 (a) 실제 표적 (b) SAR 영상.....	83
그림 4.30. 추출된 산란점(향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	84
그림 4.31. 추출된 산란점(향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	85
그림 4.32. 수렴 곡선(12개의 관측 방위각).....	86
그림 4.33. 추출된 특징점(PCA, 12개의 관측 방위각).....	87
그림 4.34. 추출된 특징점(PCA+LDA, 12개의 관측 방위각) ...	87

그림 4.35. 식별 결과(실험, 12개의 관측 방위각)	88
그림 4.36. 추출된 특징점(PCA, 6개의 관측 방위각)	89
그림 4.37. 추출된 특징점(PCA+LDA, 6개의 관측 방위각)	89
그림 4.38. 식별 결과(실험, 6개의 관측 방위각)	90
그림 4.39. 추출된 특징점(PCA, 3개의 관측 방위각)	91
그림 4.40. 추출된 특징점(PCA+LDA, 3개의 관측 방위각)	91
그림 4.41. 식별 결과(실험, 3개의 관측 방위각)	92
그림 4.42. 잡음에 따른 식별 성공률(SVM 최적화 전)	93
그림 4.43. 잡음에 따른 식별 성공률(SVM 최적화 후)	94

표 목차

표 2.1. 첩 신호의 파라미터	13
표 2.2. 산란점 위치와 반사계수	13
표 3.1. 산란점 위치와 반사계수	24
표 3.2. 시험 함수	37
표 3.3. 최적화 파라미터	39
표 3.4. 시험 함수들의 최적화 결과	40
표 4.1. 시뮬레이션 환경	52
표 4.2. 커널 함수	63
표 4.3. 유전 알고리즘의 파라미터	72
표 4.4. 실험 환경	76

기호 및 약어 설명

t	시간
f_0	초기 주파수
α	Chirp rate
(x, y)	관측 위치
(x_n, y_n)	n번째 산란점 위치
R_n	관측 위치와 n번째 산란점의 거리
t_n	관측 위치와 n번째 산란점까지의 수신 시간
σ_n	n번째 산란점의 반사 계수
Φ	샘플링 매트릭스
Ψ	Representation 매트릭스 혹은 Sparse basis
A	Transformation 매트릭스
r	잔차(Residual)
λ	서포트 벡터
θ	고각
φ	방위각
$\Phi(\cdot)$	비선형 매핑 함수
$K(\cdot)$	커널 함수
BMO	Bird Mating Optimizer
BPA	후광 영사 알고리즘 (Back Projection Algorithm)
CS	압축센싱 (Compressive Sensing)
DB	데이터 베이스 (Data Base)
FBP	Filtered Back Projection
IDFT	Inverse Discrete Fourier Transform
GA	유전 알고리즘
HRRP	고해상도 거리 프로파일 (High Resolution Range Profile)
LDA	Linear discriminant Analysis
LSM	최소자승법 (Least Squares Method)
OMP	Orthogonal Matching Pursuit
PCA	Principal Component Analysis
PO	물리광학법 (Physical Optics)
Radar	레이더 (Radio detection and ranging)
RCS	레이더 반사 면적 (Radar Cross Section)
SAR	합성 개구 레이더 (Synthetic Aperture Radar)
SL	Sparsity Level
SVM	서포터 벡터 머신 (Support Vector Machine)
VNA	Vector Network Analyzer
WOA	Whale Optimization Algorithm

제 1 장 서 론

1.1 연구의 배경

레이더(Radar : Radio Detection and Ranging) 표적 식별에 대한 연구는 그림 1.1과 같이 레이더에서 송신된 전자기파가 표적에 반사되어 수신되는, 표적의 특성을 지니고 있는 신호를 이용하여 해당 표적의 종류를 구분하는 연구이다. 광학, 적외선, 초음파 센서와 달리 레이더는 다른 센서들에 비해 장거리 표적을 식별할 수 있으며, 기상 상황에 크게 영향을 받지 않는다는 장점을 가지고 있다. 레이더는 이런 장점으로 인하여 국내의 주요 군사 시설을 타격하려는 적대국의 미사일이나 폭격기를 감지하는 국방 분야나, 보행자나 차량의 식별을 통한 자율주행 분야, 또는 항공 교통 관제 시스템에 주로 사용된다.

최근 국방 분야에서 사용되는 레이더의 경우, 전투기의 표면 구조에 맞게 탑재되는 능동 위상 배열 안테나(AESA : Active Electronically Scanned Array)를 이용한 공대공 탐지에 대한 관심이 증가하고 있다[1]. 적대국의 전투기의 종류를 식별하여 해당 기종에 대한 최적의 대응을 수행하여 교전에서의 우위를 점할 수 있다. 이는 정확한 표적 식별이 바탕이 되어야 하며, 표적 식별의 정확도는 레이더로부터 수신되는 표적 정보량에 비례한다. 그러므로 고해상도의 정보를 획득할 수 있는 레이더나, 더 많은 관측 각에서의 표적 신호 수신이 필요하다.




그림 1.1. 레이더 수신 신호

Fig 1.1. Received Radar signal

레이더에 사용되는 주파수 대역에 따라 얻어지는 표적 수신 신호가 달라지는데, L-밴드(1~2 GHz)나 S-밴드(2~4 GHz) 레이더의 경우 같은 전력으로도 더 먼 거리를 탐지할 수 있으나, X-밴드(8~12 GHz) 레이더는 보다 정확한 표적 정보를 획득할 수 있다. 그러므로 X-밴드의 레이더의 사용이 표적 식별의 정확도를 향상시키는데 유리하다. 최근에는 고출력, 고온 안정성, 고전력 밀도를 가지는 질화갈륨(GaN : Gallium Nitride) 전자소자를 이용한 전력증폭기의 발달로, 고출력의 X-밴드 레이더를 탑재한 전투기의 개발이 이루어지고 있다[2]. 이러한 고출력의 X-밴드 레이더를 탑재한 전투기로 표적 식별을 수행할 경우, 보다 정확한 표적 식별이 가능하다. 그리고 공대공 탐지 상황에서는 표적의 일부 관측 각 정보만 얻을 수 있다. 본 논문에서는 X-밴드의 레이더 시스템에서의 표적 식별을 수행하였으며, 제한된 관측 각에서 얻어진 수신 신호로 보다 정확한 표적 식별을 수행하는 기법에 대한 연구를 진행하였다.

표적 식별의 단계는 그림 1.2와 같이 표적 신호 수신, 특징점 추출, 표적 식별, 판별의 단계로 이루어지는데, 그 중 특징점 추출의 단계가 표적 식별 성능에 큰 영향을 미친다. 그러므로 표적의 어떤 특성을 나타내는 레이더 수신 신호를 사용할 것인지에 대한 연구가 필요하다. 본 논문에서는 표적 특성 신호로 산란점 정보를 이용한 표적 식별에 대한 연구를 진행하였다.




그림 1.2. 표적 식별 단계

Fig 1.2. Process of target identification

표적 식별의 단계에서는 기존에 획득한 표적 데이터베이스(DB : Data

Base)와의 유사성을 비교하여 표적의 종류를 판별하게 된다. 그러므로 축적된 데이터가 필요하게 되는데, 식별의 성공률을 높이려면 표적에 대한 다양한 데이터가 필요하다. 그림 1.3과 같이 RCS 데이터를 획득하여 데이터베이스를 구축하는 경우, 표적의 고각(θ), 방위각(φ), 주파수(f) 별로 RCS를 측정하여 데이터베이스를 구축하여 표적 식별의 성공률을 높일 수 있다. 본 논문에서는 표적의 데이터베이스를 구축하고 학습과 검증 데이터로 나누어 표적 식별을 수행하였다.

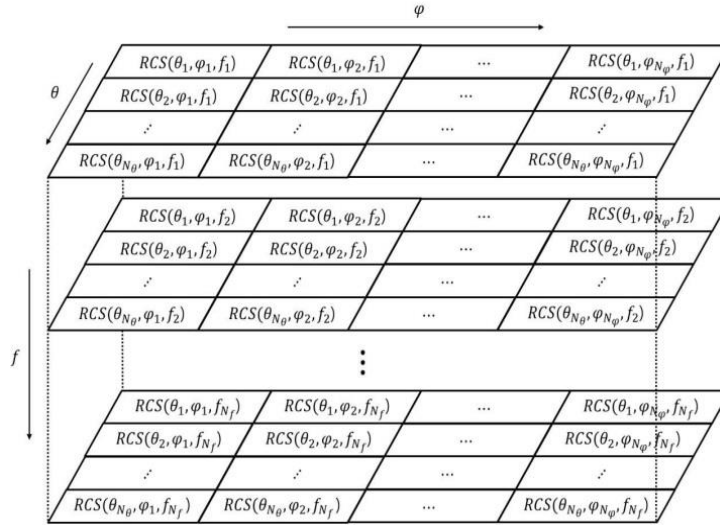


그림 1.3. 고각, 방위각, 주파수 별로 획득한 RCS 데이터베이스

Fig 1.3. RCS database acquired by elevation, azimuth, and frequency

표적 식별에 사용되는 표적 특성으로 레이더 반사 면적(RCS : Radar Cross Section), 고 해상도 거리 프로파일(HRRP : High Resolution Range Profile), 도플러(Doppler)와 같은 1차원 데이터와 합성 개구 레이더(SAR : Synthetic Aperture Radar)로부터 얻어지는 2차원 이미지가 있다[3-11]. [3]에서는 송신과 수신 위치가 다른 바이스테틱 RCS를 이용하여 전투기 표적의 식별을 수행하였으며, [5]에서는 주파수 별 스위핑하여 얻어진 광대역 RCS 이용하여 선박 표적의 식별을 수행하였다. [7]에서는 해상의 선박 표적으로부터 얻어지는 HRRP를

이용하여 표적 식별을 수행하였으며, [8], [9]에서는 HRRP를 이용하여 차량 표적의 식별을 수행하였다. [10]에서는 마이크로 도플러를 이용하여 점 산란 모델에 대한 표적 식별을 수행하였다. 위와 같은 1차원 데이터를 이용한 표적 식별의 경우에는 빠른 수신 신호의 획득 및 식별 수행이 가능하지만 관측 각에 따라 제한된 수신 신호만 획득할 수 있기에 식별 성능이 떨어진다는 단점이 있다. 그와 다르게 [11]과 같이 2차원 SAR 영상을 이용하여 산란점 모델을 생성한 후 표적 식별을 수행하는 경우, 필요한 데이터가 많아져 신호 획득과 식별 수행이 느려지지만, 보다 정확한 식별이 가능하다는 장점을 가지고 있다. 그러므로 정확한 표적 식별이 가능하며, 측정 및 연산 시간을 최소화시킬 수 있는 표적 특성을 선택하는 것에 대한 연구가 필요하다.

최근 레이더 표적 식별에서 산란점 정보를 사용하는 연구가 많이 이루어지고 있다[12–16]. 산란점은 레이더 수신 신호가 세계 나타나는 표적의 특정 부분으로 수신되는 신호의 크기와 위치 정보를 담고 있다. 이러한 산란점을 이용하면 높은 성능의 식별이 가능하다. 산란점을 추출하는 여러 기법들이 제시되어 있는데, 그 중 하나가 [12], [13]과 같이 압축 센싱을 이용하여 산란점을 추출하는 기법으로 측정 시간을 줄일 수 있다. 압축 센싱은 그림 1.4와 같이 측정과 샘플링을 하나의 과정으로 수행하여 측정 데이터의 수를 줄이는 기법이다[17].




그림 1.4. 압축 센싱의 개념도

Fig 1.4. Concept of compressive sensing

압축 센싱을 이용하면 충분한 관측 각이 확보되지 않는 상황에서도,

많은 관측 각의 데이터로 얻어진 산란점과 유사한 정보를 추출할 수 있다. 압축 센싱 알고리즘의 하나인 orthogonal matching pursuit (OMP) 알고리즘의 경우 l_1 -norm 문제를 푸는 탐욕(Greedy) 알고리즘의 하나로 반복의 과정을 통해 문제를 해결한다[18]. 이러한 OMP 알고리즘은 필요로 하는 데이터가 적어 측정 시간을 줄일 수 있지만, 추출하려는 산란점의 수가 많을 경우 연산 시간이 증가하게 된다. 본 논문에서는 이러한 연산 시간의 증가를 억제할 수 있는 향상된 OMP 알고리즘을 제시하였다.

CS를 이용한 산란점 추출 기법의 경우, 적은 데이터로 원본 데이터와 유사한 산란점 정보를 얻을 수 있으나, 표적의 관측 각이 매우 적은 경우, 정확한 산란점 정보를 얻는데 어려움이 있다. 보다 정확한 산란점을 추출하는 기법에 대한 연구 중 하나로 최적화 알고리즘을 이용한 기법이 존재한다[19–21]. 역 산란(Inverse scattering) 문제를 최적화로 해결하는 기법으로 적은 데이터로도 정확한 산란점의 정보를 추정할 수 있으나, 연산 시간의 증가한다. 이에 정확한 전역 해(Global solution)를 찾으면서도 수렴성이 높은 새로운 최적화 알고리즘에 대한 연구가 필요하다. 본 논문에서는 표적의 산란점 정보를 설계변수로 하여 최적화를 수행하며, 설계변수가 많은 고차원 최적화 문제를 잘 푸는 최적화 알고리즘을 제안하였다. [22], [23]에 나타난 것과 같이 고차원 문제를 해결하는데 나선형 탐색이 유리하므로, 제안한 혼합 유전 알고리즘의 교차(Crossover) 방식으로 나선형 탐색(Spiral search)을 선택하였다. 그리고 수렴 속도가 빠른 결정론적 알고리즘의 특성과 전역 해 탐색에 유리한 확률론적 알고리즘의 특성을 모두 가질 수 있도록 해 집단을 여러 그룹으로 나누어 각 그룹마다 다른 방식의 교차 연산을 수행하여 해의 다양성을 보존하고 수렴성을 높였다[24, 25].

다음으로 앞서 제안한 향상된 OMP 알고리즘과 고차원 혼합 유전 알고리즘의 장점을 결합한 최적의 산란점 추출 기법에 대한 연구를 진행하였다. 향상된 OMP 알고리즘을 이용한 산란점 추출 기법의 경우 측정 데이터를 줄일 수 있으나, 제한된 관측 각으로 인한 산란점

정보의 부정확성이 발생한다. 혼합 유전 알고리즘을 이용한 산란점 추출 기법은 정확한 산란점 정보를 추출할 수 있으나 연산 시간이 증가한다. 이런 두 알고리즘의 장점을 취한 최적의 산란점 추출 기법을 제안하였다. 먼저 향상된 OMP 알고리즘을 이용하여 산란점 정보를 추출한 후, 획득한 산란점 정보를 초기값으로 두고 고차원 혼합 유전 알고리즘을 이용한 최적화를 수행하였다. 그 결과 정확한 산란점 정보를 획득하면서도, 연산 시간의 증가를 억제시킬 수 있었다. 최적의 산란점 추출 기법의 검증을 위해 시뮬레이션으로 얻어진 레이더 수신 신호에 적용하였다. 3 종류의 비행체 표적들을 대상으로 수치 해석적으로 얻어진 시뮬레이션 데이터에 최적의 산란점 추출 기법을 수행하여 제안한 산란점 추출 기법의 우수성을 확인하였다.

추출된 산란점 정보를 이용하여 표적 식별을 수행하였는데, 표적 식별에 사용되는 식별기의 종류에 따라 식별 성능이 달라지게 된다. 주로 사용되는 식별기로 k -NN, Bayes, 서포트 벡터 머신(SVM : Support Vector Machine)이 있다. [26]은 k -NN 식별기를 이용하여 지표면에 묻힌 지뢰 탐지 및 식별을 수행한 논문으로, k -NN은 구현이 간단하지만 저차원 데이터의 식별에 적합하며 DB 구조에 영향을 크게 받기에 본 논문에서 사용하기에는 적합하지 않다. Bayes 식별기는 적은 양의 DB로도 잘 동작하지만, 데이터의 분포에 따른 성능 변동이 있으며, 데이터가 가우시안 분포를 갖지 않는 경우 식별 성능이 저하되는 문제가 있다[27]. SVM은 커널 함수를 이용하여 비선형 분류가 가능하며, 고차원 데이터를 식별하는데 적합한 반면, 학습 속도가 떨어진다는 문제가 있다[28]. 본 논문에서는 고차원 식별에 적합하고 커널 및 커널 파라미터 최적화를 이용한 식별 성능 향상이 가능한 SVM 식별기를 선택하여 표적 식별을 수행하였다. 최적화를 통해 다른 식별기에 비해 더 좋은 식별 성능을 가지는 것을 확인하였다.

본 논문에서 제안한 최적의 산란점 추출 기법과 최적화된 SVM 식별기를 이용하여 실제 측정 데이터에 적용하였다. 그 결과 적은 측정 데이터로도 높은 식별 성공률을 보임을 확인할 수 있었으며, 연산

증가도 억제할 수 있음을 볼 수 있었다. 공대공 표적 식별에서는 식별 수행에서 획득할 수 있는 표적의 관측각은 제한적이며, 획득한 산란점 정보의 정확성도 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 알고리즘을 적용하면 보다 정확한 표적 식별을 수행할 수 있다.

1.2 논문의 구성

본 논문은 총 5장으로 구성되어 있으며, 각 장의 연구 내용은 다음과 같다.

제 1장에서는 연구 배경, 논문 구성에 대하여 서술하였다.

제 2장에서는 레이더 수신 신호로 사용된 칩 신호를 모델링하였으며, 시뮬레이션을 통하여 레이더 수신 신호가 표적의 정보를 제대로 반영하는지 검증하였다.

제 3장에서는 산란점 추출 알고리즘에 대한 연구를 진행하였다. 먼저 압축 센싱 기반의 산란점 추출 알고리즘에 대한 연구를 제시하였는데, 압축 센싱의 개념 설명과 기존의 압축 센싱 알고리즘의 구성을 설명하였으며 다음으로 본 논문에서 제안하는 향상된 압축 센싱 알고리즘을 설명하였다. 그리고 향상된 압축 센싱 알고리즘을 간단한 시간-주파수 영역 변환 문제에 적용하여 검증하였으며, 본 논문에서 적용할 산란점 추출 문제에도 검증을 진행하였다.

최적화 알고리즘 기반의 산란점 추출 연구에서는 본 논문에서 제안하는 고차원 혼합 유전 알고리즘의 개념에 대하여 설명하였으며, 여러 최적화 시험 함수에 대한 결과를 비교하여 최적화 알고리즘의 성능을 검증하였다. 또한 산란점 추출 문제에도 적용하여 검증하였다.

제 4장에서는 최적의 산란점 추출 및 기법에 대한 연구를 진행하였다. 먼저 앞서 제안한 향상된 CS 알고리즘과 고차원 혼합 유전 알고리즘을 결합한 최적의 산란점 추출 기법을 제안하였으며, 시뮬레이션 데이터를 이용하여 검증하였다. 다음으로 식별 알고리즘에서 사용되는 여러 식별기에 대한 비교를 수행하고 본 논문에 적합한 SVM을 선택하였다. 최적화가 가능한 SVM 식별기의 최적화 과정에 대하여 설명하였고,

앞서 추출한 산란점 정보에 최적화된 SVM을 이용한 표적 식별을 수행하였다. 시뮬레이션 데이터와 실제 측정 데이터에 모두 적용하였으며, 향상된 식별 성능을 보임을 확인하였다.

제 5장에서는 본 논문의 결과를 정리하고 향후 연구에 대하여 논의하였다.

제 2 장 레이더 수신 신호 모델링

본 장에서는 산란점 추출 알고리즘을 설명하기에 앞서 본 논문에서 사용되는 레이더 신호에 대한 설명과 표적에 반사되어 수신되는 신호의 모델링을 진행하려 한다. 그리고 시뮬레이션 결과를 통해 수신 신호에 대한 검증을 진행할 것이다.

2.1 수신 신호 모델링

레이더 수신 신호는 송신 레이더의 신호 특성에 따라 다르게 수신되는데, 본 논문에서는 시간에 따라 주파수가 증가하거나 감소하는 첵 (Chirp) 신호를 레이더 송신 신호로 사용하였다. 시간에 따라 주파수가 증가하는 첵 신호는 그림 2.1과 같은 형태를 가지게 된다. 그러므로 첵 신호를 통해 얻어지는 수신 신호는 표적의 여러 주파수에 대한 특성을 한번에 얻을 수 있다.




그림 2.1. 첵 신호

Fig 2.1. Chirp signal

칩 신호 s_t 은 수식 (2.1)과 같이 표현되는데, t 는 시간을, f_0 는 초기 주파수를, α 는 시간에 따른 주파수 증가율을 나타내는 chirp rate이다[29].

$$s_t(t) = e^{(j2\pi f_0 t + j\pi \alpha t^2)} \quad (2.1)$$

칩 신호 s_t 가 표적에 반사되어 수신되는 수신 신호 s_r 는 수식 (2.2)와 같이 표현된다. (x, y) 는 관측 위치를, (x_n, y_n) 은 n 번째 산란점의 위치를 나타내며, 관측 위치와 n 번째 산란점과의 거리를 r_n , n 번째 산란점에 반사되어 관측 위치로 수신되기까지의 시간을 t_n 으로 표기하였다. s_n 은 함께 수신되는 잡음을 나타낸 것이며 σ_n 은 n 번째 산란점의 반사계수를 의미한다.

$$s_r(x, y, t) = \sum_n \sigma_n \cdot e^{(j2\pi f_0(t-t_n) + j\pi \alpha(t-t_n)^2)} + s_n \quad (2.2)$$

$$t_n = \frac{2R_n}{c}, R_n = \sqrt{(x - x_n)^2 + (y - y_n)^2}$$

수신된 신호 s_r 은 디칩(Dechirp) 과정을 거쳐 표적과 관측 위치와의 거리 정보만을 남겨둘 수 있는데, dechirp의 과정은 수식 (2.3)에 나타나 있다[30]. $(\cdot)^*$ 는 complex conjugate를 나타낸다.

$$s_d(x, y, t) = s_r^*(x, y, t) \cdot s_t(t)$$

$$= \sum_n \sigma_n \cdot e^{(j2\pi f_0 t_n + j\pi \alpha t_n^2)} \cdot e^{(j2\pi \alpha t_n t)} + s_n \quad (2.3)$$

수식 (2.3)의 $e^{(j2\pi \alpha t_n t)}$ 텀(Term)만이 시간에 따라 변하므로, 수식 (2.4)와 같이 역 푸리에 변환(Fourier transform)을 통해 산란점의 정보를 확인할 수 있다. IDFT[\cdot]은 inverse discrete Fourier transform을 나타낸다[31].

$$IDFT[r(x, y, t)] \quad (2.4)$$

위의 과정을 거쳐 표적 수신 신호의 거리 프로파일 정보를 획득할 수 있다. 레이더의 거리 분해능은 주파수의 대역폭에 반비례하므로, 주파수 스위핑을 이용하면 주파수 대역폭이 넓어진 효과를 얻을 수 있다. 그러므로 얻어진 거리 프로파일 정보는 거리 분해능이 더 향상된 고 해상도 거리 프로파일 정보이다[32]. 본 논문에서는 고 해상도 거리 프로파일 정보로부터 산란점 정보를 추출해 내고 표적 식별에 사용할 것이다. 모델링된 레이더 수신 신호의 검증을 다음 절에서 진행할 것이다.

2.2 시뮬레이션 결과

앞서 모델링한 수신 신호로 거리 프로파일 정보를 제대로 획득할 수 있는지 확인하기 위하여 시뮬레이션 데이터를 이용하여 검증하였다. 송신 신호로 사용된 첵 신호의 파라미터는 표 2.1과 같다.

표 2.1. 첵 신호의 파라미터

Table 2.1. Parameter of chirp signal

f_0 (GHz)	8
Bandwidth (GHz)	4
샘플링 수	801
주파수 스위프 시간 (s)	10^{-8}
Chirp rate (Hz/s)	4×10^{17}

첵 신호가 반사되는 표적은 3개의 산란점을 가진 표적으로 두었으며 산란점들의 위치와 반사계수는 표 2.2와 같다.

표 2.2. 산란점 위치와 반사계수

Table 2.2. Location and reflectivity of scattering center

	Position (m,m)	Reflectivity
산란점1	(-0.2, 0.05)	0.5
산란점2	(0, -0.1)	0.8
산란점3	(0.1, 0.25)	0.25

표적의 위치를 그래프로 나타내면 그림 2.2과 같으며, 관측 위치는 원점인 (0,0)이다.




그림 2.2 산란점의 위치

Fig 2.2 Location of scattering center

위의 시뮬레이션 조건에서 획득한 수신 신호를 2.1절에서 설명한 dechirp 과정과 IDFT를 통해 표적의 거리 프로파일을 획득하면 아래의 그림 2.4와 같다. 표 2.2의 정보와 비교해보면 실제 산란점들의 위치에서 반사계수에 비례하는 만큼의 피크(Peak)가 생성됨을 볼 수 있다. 본 논문에서는 첩 신호를 이용하여 산란점 추출을 진행할 것이다.




그림 2.3 거리 프로파일

Fig 2.3 Range profile

제 3 장 최적의 산란점 추출 알고리즘

본 장에서는 산란점 추출 알고리즘에 대한 상세 설명과 검증을 진행할 것이다. 먼저 앞서 서론에서 언급한 것과 같이 산란점 추출 알고리즘에 대한 연구를 크게 2 부분으로 나누어 진행할 것이다. 압축 센싱 기반의 산란점 추출 알고리즘 부분과 최적화 알고리즘 기반의 산란점 추출 알고리즘으로 나누어 설명을 진행할 것이며, 기존의 알고리즘과 본 논문에서 제안하는 알고리즘에 대해 설명한 후, 시뮬레이션 결과를 이용한 검증을 진행할 것이다.

3.1 Compressive sensing 기반의 산란점 추출 알고리즘

압축 센싱 기법은 의학, 소나 영상 등 다양한 분야에서 적용되고 있는 신호처리 기법으로 최근에는 레이더 신호 처리에서도 많이 응용되고 있다[33–35]. 먼저 기존의 압축 센싱 기법에 대해 서술한 후, 본 논문에서 제안하는 향상된 압축 센싱 기법에 대한 자세한 설명을 진행할 것이다.

3.1.1 Compressive sensing

압축 센싱 기법은 진보된 신호처리 기법의 하나로 적은 일부의 측정 데이터로부터 전체 데이터를 복원하는 목적으로 연구되었다[36]. 압축 센싱 기법은 측정과 샘플링 과정을 한 번에 수행하여 측정 시간을 줄이고, 필요한 데이터도 줄일 수 있다. 그럼에도 불구하고 압축 센싱 기법을 이용한 복원은 CS 알고리즘의 추가로 기존의 복원 기법에 비해 연산량이 증가한다는 단점이 있다. 그러므로 전체 복원 시간을 줄이기 위해서는 연산 시간을 줄이는 방법에 대한 연구가 필요하다. 본 논문에서 제시하는 변형된 CS 알고리즘은 이러한 단점을 보완하는

방향으로 연구를 진행한 결과이다.

압축 센싱 기법을 적용하기 위해서는 다음과 같은 두 조건을 만족해야 한다[17]. 첫 번째로 신호가 성김(Sparsity)을 만족해야 한다. 성김을 만족하기 위해서는 신호에서 유의미한 값을 가진 요소가 적어야 한다. 또한 측정 영역(Domain)이 아닌 다른 영역에서 압축되어 보이는 성긴 신호(Sparse signal)로 보여야 한다. 예를 들면, 시간 영역에서 많은 정보를 가진 것처럼 보이는 신호를 FFT를 통해 주파수 영역에서 보면 일부의 주파수 성분만 가지는 압축된 신호로 변환시켜 볼 수 있는 경우가 있다. 이러한 조건에서 시간 영역을 측정 영역으로 하여 압축 센싱 기법을 적용할 수 있다.

측정 영역에서 얻어진 신호를 \mathbf{x} , 성긴 영역(Sparse domain)에서 보여지는 신호를 \mathbf{s} 라 두고, Ψ 를 두 신호의 관계를 나타내는 sparse basis 또는 representation matrix라고 두고, Φ 를 sampling matrix라 하면 아래의 수식 (3.1)과 같은 관계가 성립한다. \mathbf{A} 는 sparse basis와 sampling matrix를 곱한 매트릭스로 transformation matrix로 표현한다.

$$\mathbf{x} = \Phi\Psi\mathbf{s} = \mathbf{A}\mathbf{s} \quad (3.1)$$

압축 센싱은 수식 (3.1)을 만족하면서도 가장 성긴 신호를 찾는 기법으로 아래의 수식 (3.2)와 같이 표현된다. $\|\mathbf{s}\|_0$ 은 l_0 -norm을 나타내는 것으로 0이 아닌 원소들의 수를 나타낸다.

$$\min_{\mathbf{s}} \|\mathbf{s}\|_0 \text{ subject to } \mathbf{x} = \mathbf{A}\mathbf{s} \quad (3.2)$$

두 번째로 만족해야 하는 조건은 신호의 비간섭성(Incoherence)이다. 비간섭성은 sampling matrix와 representation matrix의 비간섭성을 의미하는 것으로, 샘플링 과정에서 무작위 샘플링을 수행하여 비간섭성 조건을 만족시킬 수 있다.

레이더 신호 처리의 경우 표적으로부터 수신되는 측정 신호는 성긴 신호가 아니지만, 거리 프로파일, SAR 영상과 같이 변형된 신호의 경우 성긴 신호이므로 CS 알고리즘을 적용하기에 적합하다고 볼 수 있다.

CS 알고리즘은 크게 2 가지 종류로 나눌 수 있다. 첫 번째로 l_1 -norm 최소화 문제를 푸는 알고리즘이 있으며, 두 번째로 OMP, Compressed Sensing Matching Pursuit(CoSaMP), Bayesian Fast Relevance Vector Machine(RVM)과 같은 탐욕 알고리즘 기반이 있다[37–39]. 탐욕 알고리즘은 l_1 -norm 최소화를 푸는 알고리즘에 비해 더 빨리 해를 찾을 수 있으므로 본 논문에서는 탐욕 알고리즘 기반의 CS에 대한 연구를 진행하였다.

먼저 OMP 알고리즘에 대해 개략적으로 알아보려 한다. OMP 알고리즘은 Mallat에 의해 제안된 탐욕 알고리즘의 하나로 반복에 의해 수행된다. 매 반복 마다, 알고리즘은 0이 아닌 성분을 추정하고, 다음 반복에서 이전에 추정된 0이 아닌 성분을 원 신호에서 제거한 잔차(Residual) 신호로부터 다시 0이 아닌 성분을 추정한다. 이러한 방식으로 순차적으로 가장 큰 0이 아닌 성분을 추정해가는 것이 OMP 알고리즘이다. OMP 알고리즘의 순서도는 그림 3.1에 나타나있다.

먼저 초기화(Initialization) 후 OMP 알고리즘은 대리 신호(Signal Proxy) \mathbf{x}_s 를 계산한다. 대리 신호 \mathbf{x}_s 는 이전 반복의 잔차 \mathbf{r}_{i-1} 에 \mathbf{A}^T 를 곱하여 얻을 수 있는데, 이는 transformation matrix \mathbf{A} 를 orthogonal matrix로 보기 때문이다. 그러므로 수식 (3.3)과 같이 성긴 신호 \mathbf{s} 와 유사한 \mathbf{x}_s 를 추정할 수 있다.

$$\mathbf{x}_s = \mathbf{A}^T \mathbf{r}_0 = \mathbf{A}^T \mathbf{x} = \mathbf{A}^T (\mathbf{A} \mathbf{s}) \approx \mathbf{s} \quad (3.3)$$

다음 단계에서 OMP 알고리즘은 대리 신호 \mathbf{x}_s 를 이용하여 성긴 신호 \mathbf{s} 의 가장 큰 성분에 관련된, transformation matrix 내의 위치인 서포트(Support) λ_i 를 추정할 수 있다. Transformation matrix \mathbf{A} 에서

획득한 서포트 λ_i 의 성분들만을 추출하여 이전 세대의 \mathbf{A}_{i-1} 과의 합을 통해 \mathbf{A}_i 를 획득할 수 있다. 다음으로 최소자승법(LSM : Least Squares Method)을 이용하여 성긴 신호 $\hat{\mathbf{s}}_i$ 을 추정할 수 있다. 최소자승법은 목표로 하는 신호와의 오차의 제곱을 최소화하도록 하는 기법으로 inverse 문제를 해결하는데 유용하게 사용되는 기법이다[40]. 추정된 신호 $\hat{\mathbf{s}}_i$ 에 \mathbf{A}_i 를 곱하고 측정된 신호 \mathbf{x} 와의 차를 계산하면 i 번째 반복의 잔차 \mathbf{r}_i 를 구할 수 있다. 이와 같은 과정을 sparsity level (SL)에 도달할 때까지 반복하게 되는데, sparsity level은 성긴 신호에서 0이 아닌 원소의 수만큼 설정한다.




그림 3.1. OMP 알고리즘의 순서도

Fig 3.1. Flowchart of the OMP algorithm

3.1.2 향상된 CS 알고리즘

앞서 설명한 OMP 알고리즘의 경우, 어느 정도의 sparsity level을 알고 있어야 하며, 신호 \mathbf{s} 의 가장 큰 성분을 매 반복마다 하나씩 추정하게 된다. CoSaMP 알고리즘의 경우는 OMP에서 변형되어 신호 \mathbf{s} 의 큰 성분들을 매 반복마다 여러 개씩 추정하게 된다. 그러나 산란점

추출, 영상 복원과 같은 레이더 신호 처리에서는 표적으로부터 얻어지는 신호들이 최종적으로 마스킹(Masking) 처리되어 얻어지게 되므로, 특정한 임계값(Threshold) 이하의 값들은 버려지는 것이라 볼 수 있다. 그러므로 이러한 레이더 신호 처리의 특수성에서 기인한, 향상된 OMP 알고리즘을 제안하려 한다. 그림 3.2는 향상된 OMP 알고리즘의 순서도를 나타낸 것으로, 기존의 OMP와 다른 점은 다음과 같다.




그림 3.2. 향상된 OMP 알고리즘의 순서도

Fig 3.2. Flowchart of the improved OMP algorithm

대리 신호 획득 단계에서 기존의 OMP와는 다르게 반복으로 가장 큰 값의 서포트를 획득하는 대신, 향상된 OMP 알고리즘은 임계값을 이용하여 특정 임계값 이상을 가지는 서포트들의 벡터인 λ 를 한꺼번에 획득한다. 그리고 transformation matrix에서 λ 에 해당하는 부분의 행렬을 뽑아 A_λ 를 획득한다. 다음으로 성긴 신호 \hat{s} 를 최소자승법을 이용하여 획득하게 되고, 이전의 OMP 알고리즘과 다르게 알고리즘이 종료된다. 이와 같이 반복을 제거하면 기존의 OMP 알고리즘에 비해 연산 속도를 크게 향상시킬 수 있다. 제안한 알고리즘의 검증을 위해 간단한 FFT 문제와 산란점 추출 문제에 적용하여 검증을 진행하였다.

3.1.3 시뮬레이션 결과

먼저 간단한 FFT 문제를 해결하는데 향상된 OMP 알고리즘을 적용해 보았다. 아래의 수식 (3.4)와 같이 서로 다른 5개의 주파수를 가진 신호를 표현한 것이다.

$$\mathbf{x} = \sum_{k=1}^5 \sin(2\pi f_k t) \quad (3.4)$$

$$\mathbf{f} = [130, 220, 300, 390, 440] \text{ Hz}$$

수식 (3.4)의 신호를 시간 영역에서 보면 그림 3.3과 같이 여러 주파수의 신호가 혼합되어 복잡한 신호를 가지는 것을 확인할 수 있다. 측정 영역인 시간 영역에서는 성진 신호가 아니지만, FFT를 통해 주파수 영역에서 보면 5개의 주파수를 지닌 신호이므로 5 개의 피크를 가진 성진 신호가 얻어질 것이다[41].




그림 3.3. 시간 영역에서의 신호 \mathbf{x}

Fig 3.3. Signal \mathbf{x} in time domain

이 신호에서 무작위로 10%의 신호만을 샘플링하면 그림 3.4와 같이 기존의 신호와 크게 달라진 신호를 획득할 수 있다. 이러한 신호의

경우 CS를 적용할 수 있는 2 가지 조건을 만족되었으므로, 향상된 OMP 알고리즘을 적용할 수 있다. Transformation matrix \mathbf{A} 는 IDFT matrix에 sampling matrix의 곱이 되며, 잡음을 고려하여 임계값을 0.1로 두고 향상된 OMP 알고리즘을 적용하면 그림 3.5와 같은 결과를 얻을 수 있다.




그림 3.4. 10%의 무작위 샘플링된 신호

Fig 3.4. 10% randomly sampled signal




그림 3.5. 향상된 OMP 알고리즘으로 획득한 성진 신호 \mathbf{s} 의 크기

Fig 3.5. The amplitude of resultant sparse signal \mathbf{s} with improved OMP algorithm

기존의 10%의 측정 데이터만으로 5개의 주파수 성분만을 가지는 성진 신호를 잘 복원하는 것을 확인할 수 있었으며, 기존의 OMP 알고리즘에 비해 약 43%의 연산 시간을 줄일 수 있었다. SL이 5이기에 43%의 절감이 발생하였으며, SL이 높을 경우 더 많은 연산 시간의 감소가 발생할 것으로 보인다.

다음으로 이상적인 점 표적으로 구성된 표적에서의 산란점 추출 문제에 향상된 OMP 알고리즘을 적용해 보았다. 표적을 두고 원형으로 돌아가며 관측을 수행하여 측정 데이터를 획득한다고 가정하였다. 관측 각의 경우 고각 θ 는 90도로 고정한 후, 방위각 φ 만 조절하며 데이터를 획득하였다.

수신된 신호 \mathbf{x}_m 는 수식 (2.3)에 나타난 수신 신호 모델링에서 얻어진 FFT 변환되기 전의 디칩된 신호로 두었다. K 는 샘플링 수, L 은 측정 방위각의 수, N 은 산란점의 수, (x_n, y_n) 는 표적의 n 번째 산란점 위치, p_n 은 n 번째 산란점의 반사 계수, R 은 표적과 관측점 사이의 거리, $r_{l,n}$ 은 l 번째 관측점과 n 번째 산란점과의 거리, φ_l 는 l 번째 방위각을 의미한다. 잡음 n_{wg} 는 수신된 신호의 파워를 기준으로 추가된 화이트 가우시안 잡음으로 두었다.

$$\mathbf{x}_m(\varphi_l, t_k) = \sum_{n=1}^N p_n \cdot e^{\left\{j4\pi f_0 \frac{r_{l,n}}{c} + j\pi\alpha \left(\frac{2r_{l,n}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi\alpha \left(\frac{r_{l,n}}{c}\right)t_k\right\}} + n_{wg}, [L \times K] \quad (3.5)$$

$$r_{l,n} = \sqrt{(R\cos\varphi_l - x_n)^2 + (R\sin\varphi_l - y_n)^2}$$

CS를 적용하기 위해서는 수신 신호를 벡터로 표현해야 하므로, 수식 (3.6)과 같이 수신 신호 \mathbf{x}_m 를 1열 벡터로 나타낸다.

$$\mathbf{x} = [x_m(\varphi_1, t_1), x_m(\varphi_1, t_2), \dots, x_m(\varphi_1, t_K), \dots, x_m(\varphi_L, t_1), x_m(\varphi_L, t_2), \dots, x_m(\varphi_L, t_K)]^T, [K \cdot L \times 1] \quad (3.6)$$

1열 벡터인 표적 산란점의 반사 계수 \mathbf{p} 는 수식 (3.7)과 같다.

$$\mathbf{p} = [p_1, p_2, \dots, p_n]^T, [N \times 1] \quad (3.7)$$

표적의 반사계수 \mathbf{p} 와 수신 신호 \mathbf{x} 의 관계를 나타내는 representation matrix $\mathbf{\Psi}$ 는 수식 (3.8)와 같다.

$$\mathbf{\Psi} = \begin{bmatrix} e^{\left\{j4\pi f_0 \frac{r_{1,1}}{c} + j\pi \alpha \left(\frac{2r_{1,1}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{1,1}}{c}\right) t_1\right\}}, \dots, e^{\left\{j4\pi f_0 \frac{r_{1,N}}{c} + j\pi \alpha \left(\frac{2r_{1,N}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{1,1}}{c}\right) t_1\right\}} \\ \vdots \\ e^{\left\{j4\pi f_0 \frac{r_{L,1}}{c} + j\pi \alpha \left(\frac{2r_{L,1}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{L,1}}{c}\right) t_K\right\}}, \dots, e^{\left\{j4\pi f_0 \frac{r_{L,N}}{c} + j\pi \alpha \left(\frac{2r_{L,N}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{L,N}}{c}\right) t_K\right\}} \end{bmatrix} \quad (3.8)$$

, $[K \cdot L \times N]$

수신 신호 \mathbf{x} 는 샘플링 매트릭스 $\mathbf{\Phi}$ 와 representation matrix $\mathbf{\Psi}$ 를 \mathbf{p} 에 곱하여 얻어진다. 표적이 있는 픽셀의 반사 계수 \mathbf{p} 는 성긴 신호이다. 그리고 얻어진 수신 신호는 \mathbf{x} 는 성긴 신호가 아니며, 무작위 샘플링을 수행하면, 아래의 수식 (3.9)와 같은 CS 문제가 된다.

$$\mathbf{x} = \mathbf{\Phi} \mathbf{\Psi} \mathbf{p} = \mathbf{A} \mathbf{p} \quad (3.9)$$

2.2절의 시뮬레이션 환경에서 사용된 첩 신호의 파라미터를 똑같이 사용하였으며, 표적과 관측 점과의 거리인 $R=4\text{m}$ 로, 관측 방위각의 수인 $L=12$ 개로 설정하였으며, 무작위로 선택된 관측 점에서 측정이 이루어졌다. 산란점과 관측 점 위치가 그림 3.6에 표시되어 있다.

좌표의 중심에 8개의 산란점을 가진 표적을 두었으며, 임의로 12개의 관측 방위각 $\varphi = [54 \ 86 \ 90 \ 104 \ 116 \ 158 \ 185 \ 188 \ 232 \ 241 \ 285 \ 360]^\circ$ 를 선택했다. 그리고 수신되는 신호에 10 dB 화이트 가우시안 잡음을 추가하였다. 표적의 산란점들의 위치와 반사 계수는 아래의 표 3.1과 같다.




그림 3.6. 산란점 위치와 관측점 위치


Fig 3.6. The position of scattering center and observation point

표 3.1. 산란점 위치와 반사계수


Table 3.1. Location and reflectivity of scattering center

	Position (m,m)	Reflectivity
산란점1	(0, -3)	1
산란점2	(-0.225, -0.1125)	0.85
산란점3	(0.225, -0.15)	0.7
산란점4	(0, 0)	0.9
산란점5	(-0.3375, 0.15)	0.75
산란점6	(0.3, 0.225)	0.95
산란점7	(-0.1125, 0.3375)	0.75
산란점8	(0.1125, 0.3375)	0.9

비교를 위해 기존의 OMP 알고리즘과 향상된 OMP 알고리즘을 모두 적용하여 산란점 추출을 진행하였다. 산란점 추출 결과는 아래의 그림 3.7에 나타나있다. 기존의 OMP 알고리즘에 비해 제안된 OMP 알고리즘은 81.2%의 연산 시간이 줄어들었으며, 유사한 성능을 보였다.



(a)




(b)


그림 3.7. (a) 추출된 산란점(향상된 OMP) (b) 추출된 산란점(OMP)

Fig 3.7. (a) Extracted scattering center(Improved OMP) (b) Extracted scattering center(OMP)

실제 산란점의 위치를 정확하게 추정하는 것을 확인할 수 있었으며, 산란점의 반사 계수 값들도 거의 일치하였다. 또한 CS가 아닌 다른 영상 복원 방법과의 비교를 위하여 후광 영상 알고리즘 (BPA : Back Projection Algorithm)에 의해 얻어진 영상과 비교해 보았다[42, 43].



(a)



(b)

그림 3.8. (a) 추출된 이미지(BPA, 12개의 임의의 관측 방위각) (b) 추출된 이미지(BPA, $\phi = 0 \sim 359^\circ$)

Fig 3.8. (a) Extracted image(BPA, 12 randomly selected observation azimuth angles) (b) Extracted image(BPA, $\phi = 0 \sim 359^\circ$)

BPA는 SAR 영상 복원 알고리즘의 하나로 시간 영역에서의 신호 처리를 통해 얻어진다. 임의의 12개의 관측 방위각을 사용한 CS와 동일한 방위각만을 사용한 BPA 영상과 1도 간격의 360개의 방위각을 모두 사용한 BPA 영상을 획득하였으며, 그 결과는 그림 3.8과 같았다. 그림 3.8(a)의 경우 CS와 동일한 12개의 방위각만을 사용한 결과로 어느 정도 산란점의 위치가 보이지만 열화가 발생하여 반사 계수의 값이 부정확하며, 산란점 주변의 일부 픽셀의 경우 상당히 높은 반사 계수가 나타나는 것을 볼 수 있다. 그러므로 CS가 적은 관측 각에서 얻은 데이터로 보다 정확한 산란점 정보를 얻을 수 있음을 알 수 있다.

그림 3.8(b)는 1도 간격으로 0~359도의 방위각에서 얻은 데이터를 모두 사용하여 영상을 복원한 결과이다. 결과를 확인해 보면 산란점의 위치는 잘 추정하는 것으로 보이나, 산란점의 반사 계수에 약간의 오차가 존재하며, 산란점 주변의 픽셀에서 반사 계수 값이 어느 정도 나타나는 것을 알 수 있다. 향상된 OMP로 얻어진 그림 3.7(a)과 비교해 보면, 향상된 OMP가 BPA보다 산란점 정보를 잘 추출하며 복원된 영상에 마스킹을 적용한 것과 같은 효과를 보여, 실제 표적 식별을 수행하는데 더 유용할 것으로 보인다. 연산 시간을 비교해 보면, 향상된 OMP를 사용하여 산란점을 추출하는 경우 약 0.4153초의 연산 시간이 걸렸으며, 임의의 12개의 방위각을 이용한 BPA의 경우 약 0.0616초가 걸렸고, 360개의 모든 방위각을 이용한 BPA의 경우 약 0.4492초가 걸렸다. 이로 보아 12개의 방위각을 사용한 BPA 보다 시간이 많이 걸리지만 산란점 추출 성능은 뛰어나며, 360개의 방위각을 사용한 BPA와 성능은 유사하지만, 연산 시간은 약 7.57% 적게 걸리는 것을 확인할 수 있다. 보다 적은 관측 각의 데이터를 사용할 경우 산란점의 정확도는 떨어지나 연산 시간은 더 감소할 것이다. 본 논문에서는 향상된 OMP를 적용하여 추출된 산란점 정보를 기반으로 표적 식별을 진행한다. 다음 절에서는 또 다른 산란점 추출 방법 중의 하나인 최적화 기반의 산란점 추출에 대한 연구를 진행할 것이다.

3.2 최적화 알고리즘 기반의 산란점 추출

최적화 알고리즘을 적용하여 표적의 산란점을 추출하는 연구가 많이 이루어지는데, 본 논문에서는 산란점 정보를 설계 변수로 두고, 수신된 신호와의 오차를 최소화하는 최적화를 수행하여 표적의 산란점 정보를 획득할 것이다. 표적의 크기와 형태에 따라 산란점의 위치와 수가 다른데, 복잡한 표적일수록 산란점의 수가 많아지는 경향을 보인다. 그러므로 많은 설계 변수를 가진 문제를 해결할 수 있는, 즉 고차원 최적화 문제를 풀 수 있는 최적화 알고리즘에 대한 필요가 발생한다.

최적화 알고리즘은 크게 결정론적(Deterministic) 알고리즘과 확률론적(Stochastic) 알고리즘으로 나누어져 있다. 결정론적 알고리즘은 conjugate gradient, steepest descent, gradient descent 알고리즘과 같이 지역 탐색(Local search)에 강하고 수렴 속도가 빠른 알고리즘이다[44-46]. 그러나 전역 탐색이 약하며, 그로 인해 최적해를 찾지 못할 확률이 높다는 단점이 존재한다. 확률론적 알고리즘은 전역 탐색 능력을 강화하기 위해 확률적인 요소를 추가한 알고리즘이다. Evolutionary strategy(ES), genetic algorithm(GA)와 같이 전역 탐색 능력이 강하며, 지역 해가 많은 문제에서도 최적해를 잘 찾는 알고리즘이다[47, 48]. 하지만 수렴 속도가 느리다는 단점이 있다. 이러한 두 알고리즘의 장점을 혼합하여 나온 것이 혼합 최적화 알고리즘이다. 혼합 최적화 알고리즘은 전역 탐색 능력도 강하며, 수렴 속도도 향상시킨 알고리즘으로, 이런 혼합 최적화 알고리즘에 대한 연구가 많이 이루어지고 있다. 본 장에서는 먼저 제시하려는 혼합 유전 알고리즘의 기반이 되는 최적화 알고리즘에 대해 간단하게 설명할 것이며, 고차원 문제를 해결하는데 강한 새로운 혼합 유전 알고리즘을 제안할 것이다. 그리고 여러 시험 함수들과 시뮬레이션 데이터를 이용한 산란점 추출 문제에 적용하여 검증을 진행할 예정이다.

3.2.1 혼합 유전 알고리즘

본 논문에서는 유전 알고리즘을 기반으로 결정론적 기법을 추가한 새로운 혼합 유전 알고리즘을 제시할 것이다. 앞서 언급한 것과 같이 표적의 산란점 수가 많을 수 있기에, 설계 변수가 많은 문제를 해결하는 최적화 알고리즘이 필요하다. 일반적인 유전 알고리즘의 경우 그림 3.9와 같은 순서로 진행된다. 초기해 생성 단계에서 GA의 인구수와 같은 임의의 n 개의 해를 생성하게 되며, 다음으로 선택, 교차, 변이의 단계를 거쳐 새로운 해인 자식 해를 생성하게 된다. 다음으로 생성된 자식 해를 기존의 부모 해 집단과 비교하여 대치를 수행하게 되며, 마지막으로 수렴 여부를 판별하여 다음 세대로 넘어갈 해를 결정하게 된다[48].

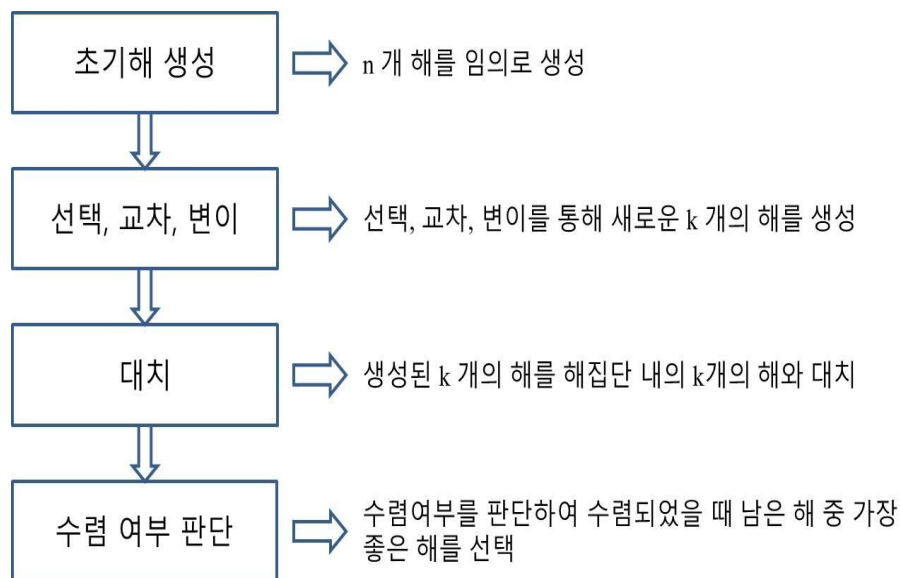


그림 3.9. 유전 알고리즘의 순서도

Fig 3.9. Flowchart of the GA

생성되는 자식 해의 경우, 앞서 어떤 선택, 교차, 변이 전략을 택하였는지에 따라 얻어지는 자식 해가 달라진다. 그 중 어떤 교차 전략을 선택하는지에 따라 생성되는 자식 해의 특성에 큰 영향을 주게

된다. 일점 교차, 다점 교차, 균등 교차, 산술적 교차 등 여러 가지 종류의 교차 전략이 존재하며, 본 논문에서는 whale optimization algorithm (WOA)에서 영감을 얻어 나선형 교차 전략을 택하였다.

WOA 알고리즘은 혹등고래가 먹이를 사냥하는 방법을 모사한 알고리즘으로, 나선형으로 돌며 먹이를 포위하는 행동에서 영감을 받아 나선형 탐색을 수행한다[22]. 이러한 나선형 탐색은 고차원 최적화 문제를 해결하는데 강점을 가진다. 본 논문에서는 나선형 탐색 방법을 자식 해를 생성하는 교차 전략으로 사용하였다.

혼합 유전 알고리즘을 생성하는 방식은 3 가지로 나눌 수 있다. 첫 번째는 결정론적 최적화 방법으로 얻어진 해를 GA의 초기 해로 사용하는 방법이다. 두 번째는 결정론적 최적화 방법의 탐색 전략을 GA의 교차 전략으로 사용하는 방법이다. 마지막은 GA로 얻어진 해들에 결정론적 최적화 방법을 적용하는 것이다[49]. 첫 번째 방법은 특정 문제를 푸는데 적합하지만, 일반적인 문제에 적용하는데 어려움이 있다. 두 번째 방법은 수렴을 향상시키지만 전역 해를 찾는 성능이 감소하게 된다. 마지막 방법은 기존의 GA를 수행하는 시간에 결정론적 최적화 수행 시간도 추가되므로, 연산 시간이 오래 걸린다는 단점이 있다.

이러한 문제점을 해결하면서 전역 해 탐색 능력을 높이기 위하여 bird mating optimizer (BMO) 알고리즘의 그룹을 나누어 서로 다른 교차 전략을 적용하는 기법을 참고하였다. BMO 알고리즘은 조류들의 종에 따라 다른 짝짓기 방식을 가지고 있다는 점에서 영감을 받아 만들어진 알고리즘이다[24]. 해 집단을 여러 그룹으로 나누어 서로 다른 교차 전략을 적용하여 해의 다양성을 높일 수 있다. 본 논문에서는 이러한 BMO의 교차 전략을 변형하여, 해 집단을 결정론적 최적화 방식으로 탐색하는 집단과, 지역 탐색에 강한 집단, 전역 탐색에 강한 집단, 무작위 탐색을 하는 집단으로 나누어 서로 다른 교차 전략을 수행하였다. 제안하는 혼합 유전 알고리즘에 대한 상세 설명은 아래에서 진행될 것이다.

본 논문에서 교차 전략으로 선택한 나선형 교차 전략은 아래의 수식 (3.10)과 같은 방식으로 자식 해를 생성하게 된다. \mathbf{X}_c 는 자식 해를 의미하며, $\mathbf{X}_1, \mathbf{X}_2$ 는 선택된 두 부모 해를 나타낸다. 그리고 r 는 $-1 \sim 1$ 사이의 임의의 값을 나타낸다.

$$\mathbf{X}_c = |\mathbf{X}_2 - \mathbf{X}_1| \cdot e^{r \cos(2\pi r)} + \mathbf{X}_1 \quad (3.10)$$

나선형 교차 전략에 의해 생성되는 자식 해들은 그림 3.10과 같은 형태로 \mathbf{X}_1 과 \mathbf{X}_2 의 사이를 회전하며 생성되게 된다.




그림 3.10. 나선형 교차

Fig 3.10. Spiral crossover

이와 같은 나선형 교차는 GA에서 주로 사용되는 산술적 교차에 비해 설계변수가 많은 문제를 잘 해결한다는 강점을 가지고 있다. 앞서 설명한 것과 같이 제안하는 교차원 혼합 유전 알고리즘에서는 여러 그룹으로 나누어 서로 다른 교차 전략을 적용하며, 나선형 교차 전략을 기본으로 변형된다.

제안하는 교차원 혼합 유전 알고리즘에서는 해 집단을 목적함수 (Objective function)의 값에 따라 4개의 그룹으로 나누었다. 가장

좋은 목적 함수 값을 가지는 해들은 최고 그룹(Best group)으로 두었으며, 이 그룹의 주변에 더 좋은 값을 가지는 해들이 있을 확률이 높으므로, 지역 탐색 능력이 뛰어난 gradient descent algorithm을 적용하였다. 다음으로 좋은 목적 함수 값을 가진 해들을 지역 그룹(Local group)으로 두었으며, 지역 탐색이 강하며, 확률론적인 요소도 추가된 교차 전략을 선택하였다. 그리고 세 번째로 좋은 목적 함수 값을 가진 해들을 전역 그룹(Global group)으로 두었으며, 전역 탐색 능력이 강하며, 해의 다양성을 유지할 수 있는 교차 전략을 선택하였다. 마지막으로 목적 함수 값이 가장 나쁜 해들은 무작위 그룹(Random group)으로 두고 임의의 부모 해를 생성하여 교차 전략을 수행하였다.

최고 그룹의 경우 앞서 설명한 것과 같이 gradient descent 알고리즘을 적용하여 자식 해를 찾았다. Gradient descent 알고리즘은 함수 값의 변화가 가장 큰 방향을 구하여 그 반대 방향으로 가면 극소점을 찾을 수 있다는 개념에서 나온 알고리즘으로 지역 탐색에 특화된 알고리즘이다[46].

나머지 그룹들은 기본적으로 자신의 그룹에서 하나의 부모 해를 선택하며 나머지 부모 해는 최고 그룹에서 선택하여 나선형 교차 전략을 적용한다. 이는 좋은 해 집단을 중심에 두고 나선형으로 돌아가며 해를 탐색하기 위함이다.

지역 그룹은 아래의 수식 (3.11)과 같은 방법으로 자식 해를 생성한다. 지역 그룹의 교차 전략을 통해 생성되는 자식 해 $\mathbf{X}_{c,local}$ 은 지역 그룹 내에서 선택된 부모 해 $\mathbf{X}_{p,local}$ 과 가장 가까운 최고 그룹의 해인 $\mathbf{X}_{p,best}$ 를 나머지 부모 해로 선택하여 자식 해를 생성한다. 이와 같은 교차 전략을 통해 근처 최고 그룹의 해 주변을 탐색하여 지역 탐색 능력을 향상시켰다.

$$\mathbf{X}_{c,local} = |\mathbf{X}_{p,best} - \mathbf{X}_{p,local}| \cdot e^r \cos(2\pi r) + \mathbf{X}_{p,best} \quad (3.11)$$

전역 그룹의 교차 전략은 수식 (3,12)과 같다. 전역 그룹의 교차 전략을 통해 생성되는 자식 해 $X_{c,global}$ 은 전역 그룹 내에서 선택된 부모 해 $X_{p,global}$ 과 최고 그룹의 해들 중에서 무작위로 선택된 $X_{r,p,best}$ 를 부모 해로 두고 자식 해를 생성한다. 전역 그룹의 해들은 해 집단 내에서 목적 함수 값이 나쁜 그룹이므로 좀 더 넓은 범위를 탐색할 필요가 있기에, 부모 해로 선택되는 최고 그룹의 해를 무작위 선정하였다.

$$X_{c,global} = |X_{r,p,best} - X_{p,global}| \cdot e^r \cos(2\pi r) + X_{p,global} \quad (3.12)$$

무작위 그룹은 아래의 수식 (3.13)와 같은 방법으로 자식 해를 생성한다. 무작위 그룹은 해의 다양성을 보존하기 위한 집단으로 생성되는 자식 해 $X_{c,random}$ 은 무작위로 생성된 부모 해 $X_{p,random}$ 과 최고 그룹에서도 가장 좋은 값을 가지는 최적 해(Best solution) X_{best} 를 나머지 부모 해로 선택하여 자식 해를 생성한다. 이와 같은 방법으로 자식 해를 생성함으로써 세대가 지날수록 줄어드는 해의 다양성을 어느 정도 보존해 줄 수 있다.

$$X_{c,random} = |X_{best} - X_{p,random}| \cdot e^r \cos(2\pi r) + X_{p,random} \quad (3.13)$$

제안한 혼합 유전 알고리즘의 자식 해 생성 방식이 그림 3.11에 정리되어 있다. 앞서 설명된 것과 같이 최고 그룹의 해는 근방의 더 나은 해를 탐색하며, 지역 그룹의 해는 주변에 가장 가까운 최고 그룹의 해의 주변을 나선형으로 돌아가며 탐색하게 된다. 전역 그룹의 해는 무작위로 선택되는 최고 그룹 해의 주변을 탐색하게 되므로, 가까운 최고 그룹의 해가 아닌, 좀 더 떨어진 최고 그룹의 해 주변을 탐색할 수 있다. 마지막으로 무작위 그룹은 무작위로 생성한 해를 최적 해의 주변을 탐색하도록 한다.



그림 3.11. 혼합 유전 알고리즘의 자식 해 생성 방법

Fig 3.11. Method of child solution generation in hybrid GA

그림 3.12는 제안한 혼합 유전 알고리즘의 순서도를 나타낸 것이다. 알고리즘의 단계는 다음과 같다.

Step 1) 초기화 : 먼저 초기화 단계에서 임의의 해 집단을 생성하게 된다. 생성되는 해들은 유전 알고리즘에서 설정된 인구 수만큼 생성되며 주어진 경계 조건 내에서 무작위로 생성하게 된다.

Step 2) 거리 계산 및 분류 : 교차 전략에서 필요한 생성한 해 집단들 사이의 거리를 계산하며, 목적 함수 값을 구하여 해 집단을 4개의 그룹으로 분류(Classification)한다.

Step 3) 교차 : 나뉜 그룹에 따라 교차 전략을 수행한다. 그룹 별로 서로 다른 교차 전략을 수행하여 자식 해를 생성한다.

Step 4) 변이 : 해의 다양성을 유지하기 위하여 생성된 자식 해의 일부 유전자를 변화시킨다. 변이되는 유전자는 경계범위 내에서 무작위 값으로 생성된다.

Step 5) 대치 : 앞선 교차, 변이 단계를 거쳐 최종적으로 얻어진 자식 해들을 다음 세대의 부모 해로 사용한다. 여러 가지 대치 방법이 존재하는데 본 논문에서는 엘리트(Elite) 집단의 개념을 사용하여 그 세대의 부모 해와 생성된 자식 해들 중에서 가장 좋은 목적 함수 값을 가진 해들만을 다음 세대로 전달한다.

Step 6) 수렴 판별 : 수렴 판별은 구해진 해들이 최적 해에 수렴하였는지를 판별하는 부분으로, 본 논문에서의 해 집단의 상위 20%의 해들의 평균이 5 세대 전의 평균에 비해 허용오차(Tolerance) 이하의 변화를 보이면 수렴한 것으로 판별하였다[50].

Step 7) 위의 step 6에서 수렴되지 않은 것으로 판별되면 step 2~6까지의 과정을 매 세대마다 반복 수행하며, 수렴된 것으로 판별하면 알고리즘을 종료하고 최적 해를 구한다.

제안한 고차원 혼합 유전 알고리즘을 검증하기 위하여 여러 시험 함수들과 산란점 추출 문제에 적용하여 그 결과를 확인하였다.

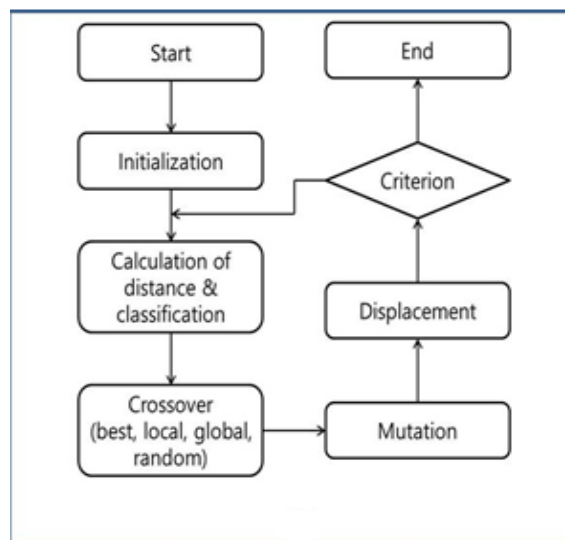


그림 3.12. 혼합 유전 알고리즘의 순서도

Fig 3.12. Flowchart of hybrid GA

3.2.2 시뮬레이션 결과

최적화 알고리즘의 경우 일반적인 성능 비교를 위한 시험 함수들이 존재하며, 여러 최적화 논문에서는 몇 가지 시험 함수에 대한 성능 비교를 수행하여, 최적화 알고리즘의 성능을 평가한다[51, 52]. 먼저 일반적인 최적화 함수들에 대한 제안한 알고리즘의 성능을 비교하기 위하여 아래와 같은 7개의 시험 함수들에 대하여 최적화를 수행하였다. 표 3.2은 시험 함수들의 수식과 최적 해, 그리고 탐색 영역을 나타낸 것이다. n 은 설계 변수의 차원수를 나타낸다. 지역 최소값들이 많아 최적 해를 찾기 힘든 함수들과 해 집단의 기울기가 완만하여 정확한 최적 해를 찾기 힘든 여러 시험 함수들에 적용하여 보았다. f_1 은 Rastrigin 함수를, f_2 는 Ackley 함수를, f_3 는 Schwefel 함수를, f_4 는 Sphere 함수를, f_5 는 Zakharov 함수를, f_6 는 Rosenbrock 함수를, f_7 은 Styblinski-Tang 함수를 의미한다.

위의 시험 함수들을 그래프로 표현한 것이 그림 3.13이다. 실제 시험 함수들은 2차원 이상의 함수들이지만 그래프로 표현하기에 한계가 있으므로 2차원일 때의 함수로 나타냈다. 시험 함수들에 대하여 본 논문에서 제안한 혼합 유전 알고리즘을 적용하여 검증을 진행하였다.

표 3.2. 시험 함수

Table 3.2. Test function

시험 함수	최적 해	탐색 영역
Rastrigin $f_1(\mathbf{x}) = 10n + \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)]$	$f(0, \dots, 0) = 0$	$(x_i \in [-5.12, 5.12])$
Ackley $f_2(\mathbf{x}) = -20e^{-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}} - e^{\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$	$f(0, \dots, 0) = 0$	$(x_i \in [-32.768, 32.768])$
Schwefel $f_3(\mathbf{x}) = 418.9829n - \sum_{i=1}^n x_i \sin(\sqrt{ x_i })$	$f(420.9687, \dots) = 0$	$(x_i \in [-500, 500])$
Sphere $f_4(\mathbf{x}) = \sum_{i=1}^n x_i^2$	$f(0, \dots, 0) = 0$	$(x_i \in [-5.12, 5.12])$
Zakharov $f_5(\mathbf{x}) = \sum_{i=1}^n x_i^2 + \left(\sum_{i=1}^n 0.5ix_i\right)^2 + \left(\sum_{i=1}^n 0.5ix_i\right)^4$	$f(0, \dots, 0) = 0$	$(x_i \in [-5, 10])$
Rosenbrock $f_6(\mathbf{x}) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$f(1, \dots, 1) = 0$	$(x_i \in [-5, 10])$
Styblinski-Tang $f_7(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^n (x_i^4 - 16x_i^2 + 5x_i)$	$f(-2.903534, \dots) = -39.16599n$	$(x_i \in [-5, 5])$

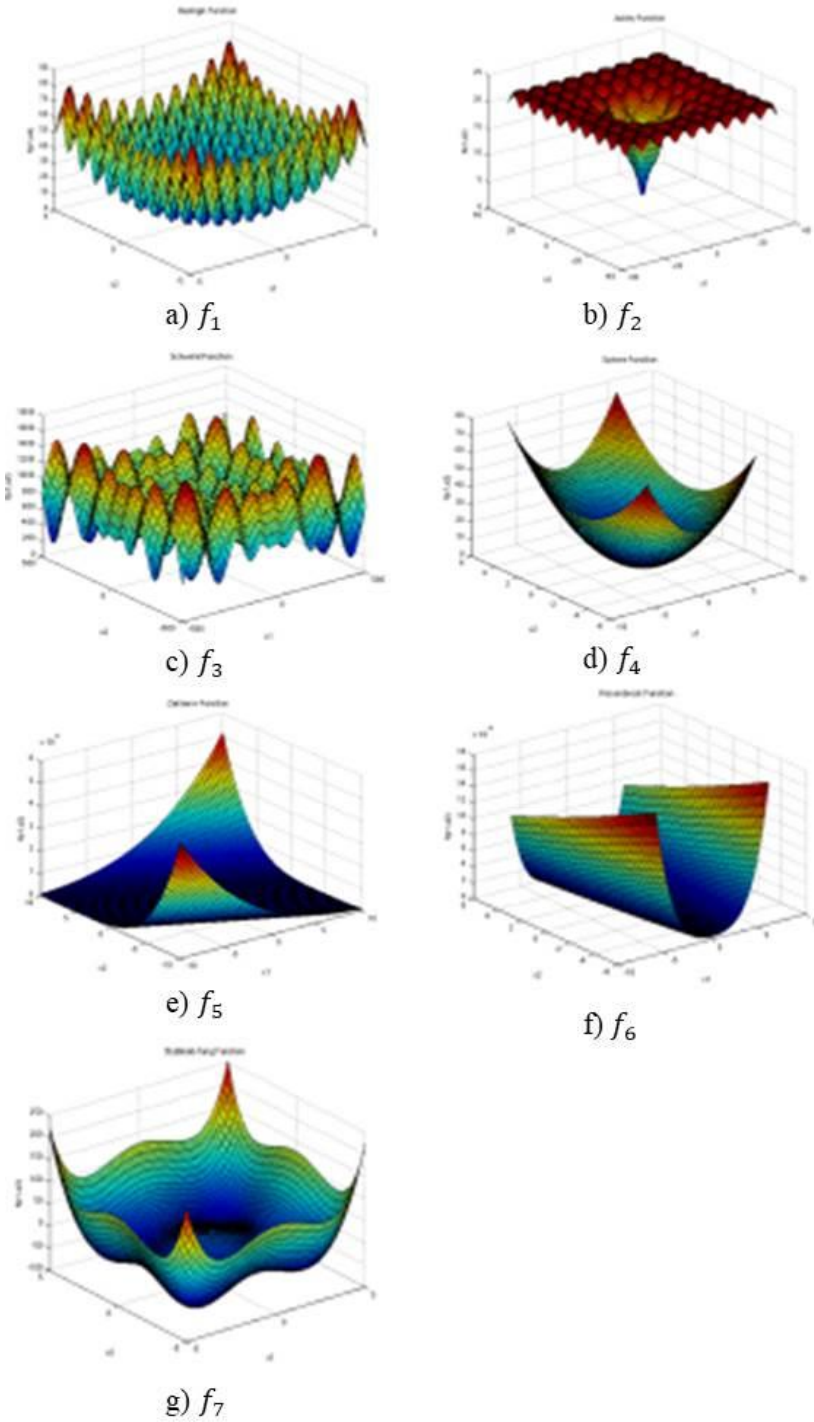


그림 3.13. 혼합 유전 알고리즘의 평가를 위한 시험 함수
 Fig. 3.13. Test function for the verification of hybrid GA

결과의 비교를 위해 제안한 알고리즘이 영향을 받은 WOA와 BMO 알고리즘의 성능을 함께 확인하였다. 최적화를 위한 파라미터 설정은 표 3.3과 같다. 고차원 최적화 성능을 알아보기 위해 설계변수의 수를 100으로 설정하였다. 세대 수는 100으로 두었으며, 종료 조건을 만족하면 바로 수렴되도록 하였다. 인구 수는 200으로 두었으며 4개의 그룹 별로 best 그룹은 10, local 그룹은 80, global 그룹은 100, random 그룹은 10으로 두었다.

표 3.3. 최적화 파라미터

Table 3.3. Parameter of optimization

설계변수	100
세대 수	100
인구 수	200 (best 그룹 : 10, local 그룹 : 80, global 그룹 : 100, random 그룹 : 10)
종료조건 허용오차	0.001

표 3.4는 시험 함수들의 최적화 결과를 나타낸 것이다. Rastrigin, Ackley, Sphere와 같은 시험 함수에서 WOA가 더 정확한 목적함수 값을 찾는 것을 확인할 수 있다. 하지만 이미 목적함수 값의 0에 가까우므로 유의미한 차이는 아닌 것으로 볼 수 있다. 그와 다르게, Schwefel, Zakharov, Styblinski-Tang 함수에서 제안한 혼합 유전 알고리즘이 다른 알고리즘에 비해 훨씬 좋은 해를 찾는 것을 확인할 수 있으며, 함수호출 수도 적은 것을 확인할 수 있다. BMO의 경우 전체적으로 제안한 혼합 유전 알고리즘 보다 성능이 떨어지는 것을 확인할 수 있다. 그러므로, 제안한 알고리즘이 고차원 최적화에 다른 알고리즘에 비해 훨씬 적합한 것을 확인할 수 있다.

표 3.4. 시험 함수들의 최적화 결과

Table 3.4. Optimization results of test functions

시험 함수		WOA	BMO	Hybrid GA
Rastrigin	목적함수 값	2.160E-14	6.048+E2	9.937E-10
	함수호출 수	19,552	21,200	20,200
Ackley	목적함수 값	1.397E-10	2.077E+1	1.592E-6
	함수호출 수	20,000	1,957.7	20,200
Schwefel	목적함수 값	5.783E+3	2.838E+4	8.384E+2
	함수호출 수	12,726	20,240	9,576
Sphere	목적함수 값	5.114E-21	3.135E+1	6.062E-13
	함수호출 수	20,000	20,830	20,200
Zakharov	목적함수 값	1.623E+3	1.415E+3	1.388E+3
	함수호출 수	19,668	19,197	3,454
Rosenbrock	목적함수 값	9.813E+1	7.881E+4	9.802E+1
	함수호출 수	7,262	19,640	8,910
Styblinski-Tang	목적함수 값	-3.763E+3	-1.981E+3	-3.900E+3
	함수호출 수	9,308	18,342	6,254

다음으로 실제 산란점 추출 문제에 적용한 결과를 확인해 보았다.

표적으로부터 수신되는 신호 S_r 는 아래의 수식 (3.14)와 같이 표현할 수 있다. (x_m, y_m) 은 관측 위치를 나타내며, f_n 은 n 번째 주파수, σ_i 는 i 번째 산란점의 반사계수, R_i 는 i 번째 산란점과 관측 위치의 거리를 나타낸다. N은 표적의 산란점의 수를 나타낸다.

$$S_r(x_m, y_m, f_n) = \sum_{i=1}^N \sigma_i e^{-jk_n(2R_i)} \quad (3.14)$$

최소화하려는 목적함수는 아래의 수식 (3.15)과 같다. $S_E(\sigma)$ 는 설계변수로 사용된 반사계수 벡터 σ 를 통해 구해진 수신 신호를 나타낸다.

$$f(\sigma) = \min \left\{ \sum_{f_n} |S_r(x_m, y_m, f_n) - S_E(\sigma)| \right\} \quad (3.15)$$

아래의 그림 3.14는 추출하려는 산란점의 위치와 반사계수를 나타낸 것이다. 알파벳 ‘A’의 형태를 가진 표적에 대하여 WOA와 BMO, 그리고 제안한 고차원 혼합 유전 알고리즘으로 산란점을 추출한 결과 그림 3.15와 같은 추정 산란점을 획득하였다. 결과를 확인해 보면 다른 최적화 알고리즘에 비해 제안한 혼합 유전 알고리즘이 표적의 산란점 위치와 반사계수를 잘 찾는 것을 확인할 수 있었다.






그림 3.14. ‘A’ 형태의 표적


Fig. 3.14. ‘A’ shaped target



(a)



(b)



(c)

그림 3.15. (a) WOA로 추정된 산란점 (b) BMO로 추정된 산란점
제안한 혼합 유전 알고리즘으로 추정된 산란점

Fig. 3.15. (a) Estimated scatterers (WOA) (b) Estimated scatterers
(BMO) (c) Estimated scatterers (Proposed hybrid GA)

다음으로 다른 표적들에도 적용하여 그 결과를 확인해 보았다. 그림 3.16는 알파벳 ‘A’ , ‘O’ , ‘F’ 의 형태를 가지는 세 가지 표적에 대하여 최적화를 수행한 결과이다. 표적들의 산란점들을 잘 추정하는 것을 확인할 수 있다. 그러므로 제안한 혼합 유전 알고리즘은 산란점 추출 문제에 잘 적용됨을 알 수 있다.




그림 3.16. (a) ‘A’ 형태의 표적 (b) 추정된 산란점 (c) ‘O’ 형태의 표적
(d) 추정된 산란점 (e) ‘F’ 형태의 표적 (f) 추정된 산란점

Fig. 3.16. (a) ‘A’ shaped target (b) Estimated scatterers (c)
‘O’ shaped target (d) Estimated scatterers (e) ‘F’ shaped target (f)
Estimated scatterers

제 4 장 최적의 산란점 추출 및 식별

앞서 연구한 산란점 추출 알고리즘을 통해 표적의 특성을 반영하는 산란점 정보를 추출해 낼 수 있다. CS 기반의 산란점 추출 기법의 경우, 선택되는 관측 방위각과 수에 따라 추출되는 산란점 정보의 정확도가 달라지게 된다. 고차원 혼합 유전 알고리즘 기반의 산란점 추출은 연산 시간이 오래 걸린다. 이러한 단점들을 개선하기 위하여 앞서 연구한 산란점 추출 알고리즘들을 결합한 최적의 산란점 추출 기법에 대한 연구를 진행하였다. 다음으로 식별 알고리즘의 식별기들에 대한 연구를 진행하였으며, SVM의 최적화를 이용한 식별 알고리즘을 연구하고 성능을 비교하였다. 최적의 산란점 추출 기법과 식별 성능을 검증하기 위하여 수치해석 기법으로 얻어진 시뮬레이션 데이터와 실제 측정 실험 데이터를 이용하여 표적 식별이 성공적으로 수행되는 것을 확인하였다.

4.1 최적의 산란점 추출 기법

산란점 추출 기법으로 연구된 CS 기반의 산란점 추출 기법의 경우 임의로 선택되는 관측 방위각에 따라 추출되는 산란점 정보의 정확도가 달라지며, 관측 방위각의 수에 따라서 성능이 달라지게 된다.

아래의 그림 4.1은 3.1.3절의 시뮬레이션 상황에서 관측 방위각의 수 $L=6, 4, 3$ 일 때의 산란점 추출 결과를 나타낸 것이다. 관측 방위각을 적게 선택할수록, 정보가 적어지기 때문에 보다 정확한 산란점이 추출하기 어렵다. $L=6$ 일 때의 추출 결과인 그림 4.1(a)는 반사 계수 정보는 잘 추출하나, 산란점 주변의 픽셀에서 어느 정도의 열화가 발생하는 것을 확인할 수 있다. 그림 4.1(b)는 $L=4$ 일 때의 산란점 추출 결과로 일부 산란점의 반사 계수 값에서 오차가 발생하는 것을 확인할 수 있다. 그림 4.1(c)는 $L=3$ 일 때의 산란점 추출 결과로 일부 산란점의 경우 위치를 찾지 못하며, 반사 계수의 정확도가 크게

줄어들었다. 연산 시간은 방위각 6개의 경우 약 0.2735초, 4개의 경우 약 0.2186초, 3개의 경우 0.1983초가 걸렸다. 사용되는 방위각 정보가 많아질수록, 연산 행렬의 크기의 증가로 인해 연산 시간이 증가하기 때문이다. 그러므로 더 적은 관측 각을 사용할수록 연산 시간을 절감시킬 수 있으며, 관측 방위각이 적을 때에도 정확한 산란점 정보를 추출할 수 있는 기법에 대한 연구가 필요하다.

그리고 공대공 표적 식별과 같은 상황에서는 표적의 정보를 획득할 수 있는 관측 방위각이 제한되어 있으므로, 관측 방위각이 적어도 정확한 산란점 정보를 추출할 수 있는 알고리즘에 대한 연구가 필수적이다. 본 장에서는 기존의 CS 기반의 산란점 추출에서 발생하는 이러한 문제점을 보완하기 위하여 최적화 기반의 산란점 추출 방법을 결합하는 기법을 결합한 최적의 산란점 추출 기법을 제안하였다.






그림 4.1. (a) 표적의 산란점(향상된 OMP, $L=6$) (b) 표적의 산란점(향상된 OMP, $L=4$) (c) 표적의 산란점(향상된 OMP, $L=3$)

Fig. 4.1. (a) Scatterers of the target(Improved OMP, $L=6$) (b) Scatterers of the target(Improved OMP, $L=4$) (c) Scatterers of the target(Improved OMP, $L=3$)

4.1.1 산란점 추출 기법

향상된 OMP 알고리즘을 이용한 산란점 추출 방법의 경우 측정 데이터를 줄일 수 있으나, 제한된 관측 각으로 인해 산란점 정보의 정확성이 떨어지게 된다. 고차원 혼합 유전 알고리즘을 이용한 산란점 추출 방법은 보다 정확한 산란점 정보를 추출할 수 있지만, 알고리즘 수행 시간이 매우 오래 걸린다. 두 알고리즘의 장점만을 취하기 위해, 다음 그림 4.2와 같은 산란점 추출 방법을 제시하였다. 표적으로부터 수신된 신호에 향상된 OMP 알고리즘을 적용하여 산란점 정보를 추출한다. 다음으로 추출된 산란점 정보를 초기 해로 하여 혼합 유전 알고리즘을 수행한다. 이와 같이 추출된 산란점 정보를 초기 해로 설정하면, 기존의 혼합 유전 알고리즘으로 산란점 추출하는 것에 비해 수렴성이 증가하며, 더 정확한 해를 찾을 수 있다. 최적의 산란점 추출 기법의 검증을 위해 그림 4.1(c)의 관측 방위각이 3개 일 때의 데이터를 이용하여 산란점 추출을 수행하였다. 목적함수는 아래의 수식 (4.1)과 같다. φ_l 는 l 번째 관측각을 의미하며, $r(\varphi_l)$ 는 l 번째 관측각에서 얻어진 수신 신호를, $(\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma})$ 는 설계변수인 산란점의 위치와 반사계수를 의미한다. r_E 는 추정된 수신 신호를 의미하며, L 는 관측각의 수이다.

$$f(\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \min \left\{ \sum_{l=1}^L |IDFT[r(\varphi_l)] - IDFT[r_E(\varphi_l, \mathbf{x}, \mathbf{y}, \boldsymbol{\sigma})]| \right\} \quad (4.1)$$

그림 4.3은 최적의 산란점 추출 기법을 적용한 결과이다. 그림 4.3(a)는 최적화 5세대 후의 산란점 추출 결과를 나타낸 것이며, 그림 4.3(b)는 최적화가 완료된 후의 결과이다. 세대가 지날수록 산란점의 위치를 잘 찾아가는 것을 확인할 수 있다. 그림 4.3(b)의 결과와 그림 4.1(c)의 결과를 비교해 보면 제안한 최적의 산란점 추출 기법을 통해 보다 정확한 산란점 정보를 추출하는 것이 가능함을 알 수 있다.

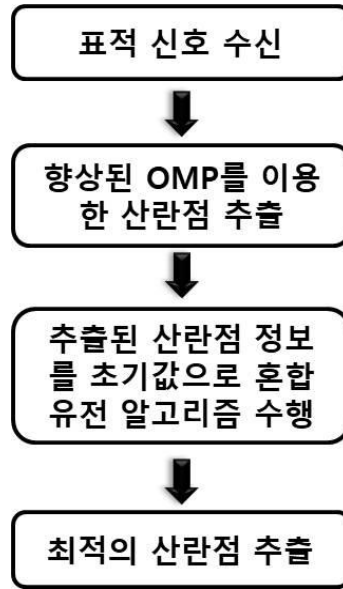



그림 4.2. 최적의 산란점 추출 기법

Fig. 4.2. Technique for optimal extraction of scattering center


그림 4.4는 최적화 알고리즘의 수렴 곡선을 나타낸 것이다. 그림 4.4(a)는 향상된 OMP로 얻은 산란점 정보를 초기 해로 주지 않은 경우의 수렴 곡선이며, 그림 4.4(b)는 획득한 산란점 정보를 초기해로 두었을 때의 수렴 곡선이다. 초기 해를 주지 않은 경우에는 50 세대를 넘어가도 최적 해에 수렴이 되지 않는 것을 확인할 수 있었다. 그에 비해 초기 해를 주는 경우에는 13 세대 정도부터 최적 해에 가까이 수렴하는 것을 확인할 수 있으며, 이것으로 보아 수렴 속도가 매우 증가하였음을 확인할 수 있다. 임의의 초기 해를 사용할 경우 약 1.5354초의 연산 시간이 걸렸으며, 향상된 OMP를 통해 얻은 산란점 정보를 초기 해로 최적화를 수행하였을 때는 약 0.3992초의 연산 시간이 걸려, 64.87%의 연산 시간이 줄어들었다. 최적화를 수행하여 증가하는 연산 시간을 크게 줄일 수 있음을 알 수 있다. 이와 같이 최적의 산란점 추출 기법으로 추출된 산란점 정보를 이용하여 표적 식별을 수행하면, 높은 식별률을 보일 것으로 생각된다.

지금까지 시뮬레이션에 사용된 표적은 이상적인 점 표적들로

이루어진 표적이다. 다중 경로와 측정 방위각에 의해 가려지는 산란점들을 제대로 반영하지 않은 레이더 수신 신호로, 실제 측정으로 얻어지는 레이더 수신 신호와 다르다. 실제 표적에의 적용 가능성을 확인하기 위하여 실제 비행기 모델들의 레이더 수신 신호를 수치해석적 기법으로 획득한 데이터에 적용하여 보았다.




(a)




(b)

그림 4.3. 최적의 산란점 결과 (a) 향상된 OMP+최적화(5세대 후) (b) 향상된 OMP+최적화

Fig. 4.3. Result of optimal scattering center (a) Improved OMP+optimization (after 5 generations) (b) Improved OMP+optimization



(a)



(b)

그림 4.4. (a) 수렴 곡선(임의의 초기해) (b) 수렴 곡선(향상된 OMP로 얻은 초기해)

Fig. 4.4. (a) Convergence curve (random initial solution) (b) Convergence curve (initial solution obtained by improved OMP)

4.1.2 시뮬레이션 결과

앞서 사용된 표적의 경우 이상적인 점 표적으로 구성되어 있으며, 산란점들 사이의 다중 경로와 관측 방위각에 의한 영향들을 고려하지 않은 수신 신호를 생성하였다. 그러므로 실제 표적에 적용하는데 적합한지에 대한 검증이 되지 않는 상태이다. 이에 대한 검증을 위하여 본 장에서는 실제 표적의 형태를 가지는 모델에 대한 수신 신호를 생성하고 산란점 추출 알고리즘을 적용하였다. 사용된 표적의 모델은 그림 4.5에 나타나 있다. 3 종류의 비행기 표적의 모델로 아래의 표 4.1의 시뮬레이션 조건에서 수치해석기법 중의 하나인 물리광학법(PO : Physical Optics)을 적용하여 데이터를 획득하였다[53, 54].




그림 4.5. (a) A-380 캐드 모델 (b) 유로파이터 캐드 모델 (c) F-15 캐드 모델


Fig. 4.5. (a) CAD model of A-380 (b) CAD model of Eurofighter (c) CAD model of F-15

표 4.1. 시뮬레이션 환경


Table 4.1. Simulation environment

주파수	8~12 GHz
편파	VV 편파
샘플링 수	1024
고각	90°
방위각	-90~90° (1° 간격)
모델 크기(A-380)	650×580 [mm]
모델 크기(Eurofighter)	500×350 [mm]
모델 크기(F-15)	600×400 [mm]


물리광학법으로 얻어진 3종류 표적의 HRRP 데이터는 그림 4.6에 나타나 있다. 얻어진 HRRP 데이터를 FBP(Filtered back-projection) 알고리즘에 적용하여 영상을 복원하였다[55, 56]. 사용한 필터는 Shepp-Logan 필터를 사용하였으며, 복원된 SAR 영상은 산란점 추출 알고리즘을 통해 얻어진 산란점 정보와의 비교에 사용되었다. 복원된 FBP 알고리즘의 결과는 그림 4.7에 나타나 있다.



(a)




(b)




(c)

그림 4.6. (a) A-380 HRRP (b) 유로파이터 HRRP (c) F-15 HRRP


Fig. 4.6. (a) HRRP of A-380 (b) HRRP of Eurofighter (c) HRRP of F-



(a)



(b)



(c)

그림 4.7. (a) A-380의 복원된 영상 (b) 유로파이터의 복원된 영상 (c) F-15의 복원된 영상

Fig. 4.7. (a) Reconstructed image of A-380 (b) Reconstructed image of Eurofighter (c) Reconstructed image of F-15

검증을 위해 먼저 3.1.2에서 제안한 향상된 OMP 알고리즘으로 산란점 추출을 수행하였다. 임의의 12개의 관측 방위각에서 데이터를 획득하였으며, 아래의 그림 4.8과 같은 산란점 정보를 획득할 수 있다.




그림 4.8. 추출된 산란점 (향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15

Fig. 4.8. Extracted scattering center (Improved OMP, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

획득한 산란점 정보에 혼합 유전 알고리즘 기반의 산란점 추출 알고리즘을 적용하면 그림 4.9의 결과를 획득할 수 있다.

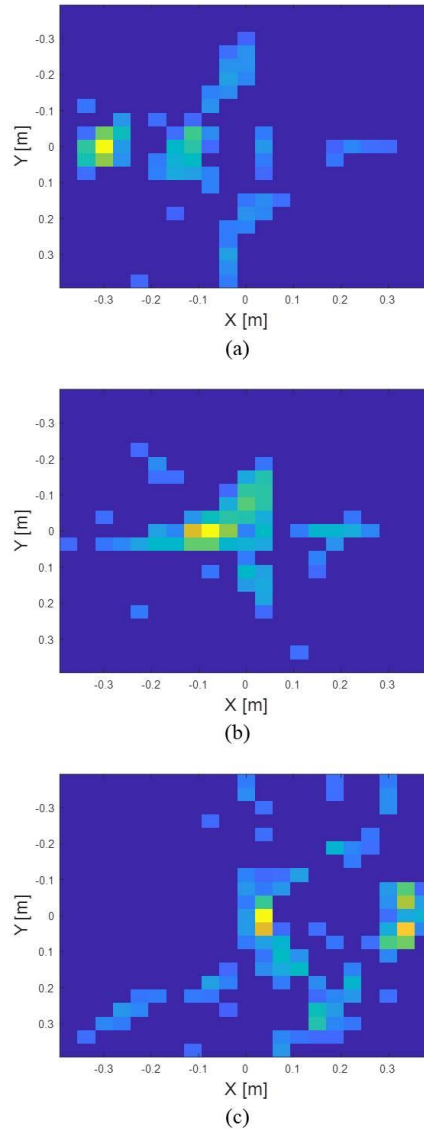


그림 4.9. 추출된 산란점 (향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15

Fig. 4.9. Extracted scattering center (Improved OMP+optimization, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

향상된 OMP만을 적용한 결과에 비해 최적화를 결합한 결과가 SAR 영상과 더 유사한 것을 확인할 수 있다. 그러므로 제안한 최적의 산란점 추출 기법이 표적의 산란점 정보를 잘 추출한다고 볼 수 있다. 획득한 산란점 정보를 이용하여 표적 식별을 수행하기에 앞서 표적 식별 알고리즘에 대한 연구를 다음 절에서 진행할 것이다.

4.2 식별 알고리즘

식별 알고리즘은 표적 신호 수신, 특징점 추출, 식별기를 이용한 표적 식별, 판별의 단계로 이루어져 있다. 그 중 특징점 추출 단계는 표적 식별 성공률에 큰 영향을 미친다. 기존의 특징점 추출 기법으로는 principal component analysis (PCA)와 linear discriminant analysis (LDA) 기법이 있으며, 레이더 표적 식별에서 주로 사용된다[57-60]. PCA는 데이터를 압축할 수 있는 새로운 좌표축으로의 변환을 통해 데이터의 차원수를 줄여 연산량을 감소시킬 수 있다. LDA는 데이터의 구별성을 높일 수 있는 새로운 좌표축으로의 변환을 통해 식별 성공률을 향상시킬 수 있다. [61]에 따르면 PCA와 LDA를 모두 적용하는 것이 표적의 식별률을 더 높일 수 있는 방법이다. 본 논문에서도 앞서 얻어진 산란점 데이터에 PCA와 LDA를 적용하여 특징점을 추출하고 표적 식별을 수행하였다.

4.2.1 식별기 연구

식별기 단계에서는 어떤 식별기를 사용하느냐에 따라 식별 성능이 달라지게 된다. 일반적으로 많이 사용되는 식별기로 k-NN, Bayes, SVM 등이 있으며, 세 식별기의 성능에 대한 분석을 진행하였다.

추출된 산란점을 특징점으로 표적 식별을 수행하였는데, 표적 식별에 사용되는 식별기의 종류에 따라 식별 성능이 달라지게 된다. 레이더 표적 식별에 주로 사용하는 식별기로는 k-NN, Bayes, 서포트 벡터

머신(SVM : Support Vector Machine) 등이 있다[62-70]. k-NN 식별기는 측정한 데이터와 표적 DB와의 거리를 구하여, 가장 가까운 k 개의 표적들의 클래스로 분류하는 방법이다. Bayes 식별기는 Bayes 룰에 기반하여 표적을 분류하는 식별기이며, SVM 식별기는 표적을 클래스에 따라 구분하는 초평면을 설정한다. k-NN은 구현이 간단하지만, 저차원 데이터의 식별에 적합하고 DB 구조에 영향을 크게 받기에 본 논문에서 사용하기에는 적합하지 않다. Bayes 식별기는 적은 양의 DB로도 잘 동작하지만, 데이터의 분포에 따른 성능 변동이 있으며, 데이터가 가우시안 분포를 갖지 않는 경우 식별 성능이 저하되는 문제가 있다. SVM은 커널 함수를 이용하여 비선형 분류가 가능하며, 고차원 데이터를 식별하는데 적합한 반면, 학습 속도가 떨어진다는 문제가 있다. 본 논문에서는 고차원 식별에 적합하고 커널 및 커널 파라미터 최적화를 이용한 식별 성능 향상이 가능한 SVM을 식별기로 선택하여 표적 식별을 수행하였으며, 기존의 방법에 비해 더 좋은 식별 성능을 가지는 것을 확인하였다. 다음으로 SVM 식별기의 기본 개념에 대하여 설명하려 한다.

4.2.2 Support vector machine을 이용한 식별 알고리즘

표적 식별에서 주로 사용되는 식별기 중 하나인 SVM은 기계학습의 하나로, 다양한 분야에서 많이 사용되어 왔다[71-73]. 앞서 언급한 것과 같이 SVM 식별기의 경우 고차원 식별에 적합하며, 최적화를 통해 DB에 맞게 식별 성능을 향상시킬 수 있다. 본 논문에서는 이러한 SVM을 이용하여 표적 식별을 수행하였다.

기본적인 선형 SVM은 특징점 공간에서 두 클래스의 데이터를 구분할 수 있는 최적의 초평면(Hyperplane)을 설정한다. 두 클래스의 점들 \mathbf{x}_i 가 벡터 공간에 주어지고, 두 클래스가 벡터 공간에서 서로 다른 영역에 존재한다고 가정하면, 아래의 그림 4.10과 같이 두 클래스는 초평면을 이용하여 선형적으로 분류가 가능하다.




그림 4.10. 초평면에 의한 분류
Fig. 4.10. Classification by hyperplane

원점을 지나는 초평면의 방정식은 $\mathbf{w}^T \mathbf{x} = 0$ 으로 둘 수 있고, 일반화하여 원점을 지나지 않는 초평면의 방정식은 $\mathbf{w}^T \mathbf{x} + b = 0$ 로 둘 수 있다. 이 평면의 법선 벡터를 \mathbf{w} 라 하면, 이 법선 벡터 \mathbf{w} 와 원점으로부터 각각의 데이터 점들까지의 벡터가 이루는 각이 90도 미만이라면 클래스 A로, 90도 이상이라면 클래스 B로 분류 가능하다. 이를 수식으로 표현하면 아래의 식 (4.2)과 같다. $\langle \cdot \rangle$ 는 두 벡터의 내적을 의미한다.

$$\begin{cases} \langle \mathbf{w}, \mathbf{x} \rangle + b \leq 0, \text{ then 'A' } \\ \langle \mathbf{w}, \mathbf{x} \rangle + b \geq 0, \text{ then 'B' } \end{cases} \quad (4.2)$$

결국, 모든 데이터들을 해당 클래스에 맞게 분류하면서, 초평면에 가장 가까운 데이터들과는 최대한 멀리 떨어지도록 초평면을 설정하는 것이 가장 주요한 문제이다. 그러므로 아래 그림 4.11과 같이 초평면에 가장 가까운 데이터와 분리 초평면 사이의 마진 d 를 최대화시켜야

한다.




그림 4.11. 초평면 선택

Fig. 4.11. Hyperplane selection

마진 d 는 아래의 수식 (4.3)와 같이 구해지게 된다[74].

$$d = \frac{2}{\|w\|^2} \quad (4.3)$$

결국, $\|w\|^2$ 최소화 문제가 된다. 그리고 앞서 본 것처럼 두 클래스에 따라 데이터들이 분류되어야 하므로, 마진 초평면을 $w^T x + b = \pm 1$ 로 두고 데이터들을 클래스에 따라 $y_i \in \{+1, -1\}$ 에 배정하면, 아래의 수식 (4.4)과 같은 제약조건을 만족시켜야 한다.

$$y_i(w^T x_i + b) \geq 1 \quad (4.4)$$

수식 (4.3)와 같은 최소화 문제를 풀면서, 수식 (4.4)의 제약조건을 만족시켜야 하는데, 이러한 문제는 라그랑주 승수법(Lagrange

Multiplier Method)을 이용하여 풀 수 있다[75, 76]. 그 식은 아래의 수식 (4.5)와 같다.

$$L(\mathbf{w}, b, \alpha) = \frac{\|\mathbf{w}\|^2}{2} - \sum_{i=1}^P \alpha_i (y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1) \quad (4.5)$$

$$s. t. y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, \dots, P$$

라그랑지안 L 은 변수 \mathbf{w}, b 에 대하여 최소화되어야 하며, 변수 $\alpha_i \geq 0$ 에 대하여는 최대화되어야 한다. 최소화를 풀기 위해, 변수 \mathbf{w}, b 로 L 을 편미분하면 아래의 수식 (4.6)를 얻을 수 있다.

$$\frac{L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^P \alpha_i y_i \mathbf{x}_i = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \quad (4.6)$$

$$\frac{L(\mathbf{w}, b, \alpha)}{\partial b} = \sum_{i=1}^P \alpha_i y_i = 0$$

변수 \mathbf{w} 가 데이터들의 선형 합으로 나타나므로, α_i 를 구하면 변수 \mathbf{w} 를 구할 수 있다. 위의 식 (4.6)를 식 (4.5)에 적용하면 아래의 수식을 얻을 수 있다.

$$L(\mathbf{w}, b, \alpha) =$$

$$\frac{1}{2} \left(\sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \right) \left(\sum_{j=1}^P \alpha_j y_j \mathbf{x}_j \right) - \left\langle \left(\sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \right), \left(\sum_{j=1}^P \alpha_j y_j \mathbf{x}_j \right) \right\rangle - \quad (4.7)$$

$$\left(\sum_{i=1}^P \alpha_i y_i b \right) + \sum_{i=1}^P \alpha_i = \sum_{i=1}^P \alpha_i - \frac{1}{2} \left(\sum_{i=1}^P \sum_{j=1}^P \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \right)$$

최종적으로 L 은 변수 α 에 대한 최대화 문제가 된다. Quadratic 프로그래밍 기법을 이용하면 α 를 구할 수 있으며, 구해진 α 를 이용하여 \mathbf{w}, b 를 순차적으로 구할 수 있다[77]. 구해진 α 중 0이 아닌 값을 가지는 데이터만 \mathbf{w} 를 구하는데 의미가 있으며, 이러한 데이터들을 support vector라 부른다.

비선형 SVM은 선형적으로 분리되지 않는 데이터들을 고차원에서의 매핑을 통해 선형적으로 분리 가능하도록 하는 방법이다. 기존의 선형적으로만 분리가 가능한 SVM과 다르게 데이터들을 비선형적으로 분리하는 효과를 줄 수 있다[78, 79]. 예를 들어 2차원에서는 선형적으로 분리되지 않는 데이터들을 3차원으로 매핑하면 그림 4.12와 같이 선형적으로 분리 가능하게 할 수 있다.




그림 4.12. 비선형 SVM

Fig. 4.12. Non-linear SVM

이런 비선형 SVM은 차원이 높아지기 때문에 연산량이 증가하는 문제가 발생한다. 이러한 문제를 해결하기 위해 커널 트릭(Kernel trick)을 이용한다[80, 81]. SVM에서는 벡터들의 내적 값들을 계산하게 되는데 비선형 매핑 함수 ϕ 를 구하지 않고 커널 함수 $\phi(x_i)^T \phi(x_j) = K(x_i, x_j)$ 를 이용해 연산량을 증가시키지 않고도 SVM 연산을 수행할 수 있다. 주로 사용되는 커널 함수로는 linear, radial basis function(RBF), polynomial, sigmoid 등이 있다. 아래의 표 4.2는 커널 함수의 종류들과 정의를 나타낸 것이다.

표 4.2. 커널 함수

Table 4.2. Kernel Functions

Linear	$K(x_i, x_j) = \langle x_i, x_j \rangle$
Polynomial	$K(x_i, x_j) = (\langle x_i, x_j \rangle + c)^d$
RBF	$K(x_i, x_j) = \gamma e^{\frac{-\ x_i - x_j\ ^2}{2\sigma^2}}$
Sigmoid	$K(x_i, x_j) = \tanh(\eta \langle x_i, x_j \rangle + v)$

어떤 커널 함수를 사용하는지에 따라 식별기의 성능이 달라지며, 같은 커널 함수에서도 파라미터를 어떻게 설정하는지에 따라 성능이 달라지게 된다. 최근 이러한 커널 함수와 파라미터 선택에 대한 연구들이 많이 진행되고 있는데, 커널 함수의 파라미터를 최적화하는 연구부터 여러 커널 함수들을 합성하여 새로운 커널 함수를 생성하는 연구도 진행되고 있다[82-86]. SVM의 커널 함수는 식별하려는 표적과 DB에 의존적이므로, DB가 변경되면 최적의 파라미터도 바뀌게 된다. 그러므로 본 논문에서는 최적화 알고리즘을 통한 커널 함수의 최적화를 선택하였다. 커널 함수의 파라미터들을 설계변수로 하여 DB에 맞게 최적화를 진행하여 적합한 커널 함수를 선택하고 최적화된 파라미터를 획득하였다, 이와 같이 SVM 식별기는 다른 식별기에 비해 성능이 우수하며, 최적화를 통해 식별 성능을 향상시킬 수 있다. 이러한 SVM 식별기의 우수성에 대한 검증을 아래에서 진행하였다.

기존의 다른 식별기에 비해 SVM이 우수함을 검증을 위해 아래의 그림 4.13과 같은 간단한 3 종류의 표적에 대하여 식별을 수행하였다. Down-scale된 3 종류의 표적들로 3.5×1.3×1 m의 제트 스키(표적1), 5 × 1.5 × 1 m의 선박(표적2), 최대 반지름 0.1 m, 높이 1 m의 잠망경(표적3)이 사용되었다. 고각은 90 도로 고정시켜 두고, 방위각

-30~30도, VV-편파, 주파수 S-밴드^[1], 주파수 샘플링 수 121개의 조건에서 표적의 RCS 데이터를 획득하였다.





그림 4.13. 식별 표적 (a) 표적 1(제트 스키) (b) 표적 2(선박) (c) 표적 3(잠망경)


Fig. 4.13. Target of identification (a) Target 1(Jet ski) (b) Target 2(Ship) (c) Target 3(Periscope)

획득한 RCS의 DB는 아래의 그림 4.14와 같이 나타난다. 얻어진 RCS 데이터를 주파수와 방위각 별로 나타낸 DB로, 실제 측정에서는 측정 방위각에서 주파수 별 RCS 값들이 얻어지게 된다.


[1] 보안 상의 이유로 구체적 주파수 밴드 생략



(a)



(b)



(c)

그림 4.14. 표적 DB (a) 표적 1 (b) 표적 2 (c) 표적 3

Fig. 4.14. Target DB (a) Target 1 (b) Target 2 (c) Target 3

획득한 RCS 데이터를 이용하여 표적 식별을 수행하였다. 본 논문에서는 DB를 학습과 검증 2 분류로 나누어 식별을 수행하는 홀드아웃 검증을 사용하였다[87]. 얻어진 DB를 학습에 사용하였으며, 식별을 위한 검증 데이터로 각 방위각에 따라 얻어지는 주파수에 따른 RCS 정보에 화이트 가우시안 잡음을 추가하여 검증 DB를 생성하였다.

세 식별기의 성능을 분석하기 위하여 k-NN, Bayes, SVM 식별기의 성능을 잡음의 SNR(Signal-to-Noise Ratio)을 변화시켜 가며 확인하였다. SNR을 0~50 dB까지 변화시켰으며, 1000번 수행하여 식별 성공률을 계산하였다. 특징점 추출에 사용된 PCA의 차원 수는 10, LDA의 차원 수는 5이며 그 결과는 아래의 그림 4.15와 같았다.

결과를 확인해 보면 세 식별기 중 SVM이 잡음에 가장 강한 것을 볼 수 있다. 또한 식별기의 성능은 특징점 추출 기법인 PCA와 LDA를 적용할 때 차원 수를 어떻게 설정하는지에 따라 달라진다. 이러한 차원 수를 유전 알고리즘을 통해 최적화 하면 아래의 그림 4.16의 결과를 얻을 수 있다. 앞서 얻어진 그림 4.14의 DB를 이용하여 표적 식별을 수행하였으며, 식별기로 SVM을 사용하였다. PCA의 차원 수 n_{PCA} 와 LDA의 차원 수 n_{LDA} 를 설계 변수로 하여 최적화를 수행하였으며, 그 결과 $n_{PCA} = 11, n_{LDA} = 11$ 일 때 SNR이 약 5 dB 더 낮아도, 최적화 전에 비해 식별 성공률이 높게 나오는 것을 확인할 수 있다. PCA, LDA의 최적화는 DB에 의존적이므로 표적의 DB가 바뀌면 새로 최적화를 수행할 필요가 있다.






그림 4.15. SNR에 따른 식별 결과 (a) k-NN (b) Bayes (c) SVM

Fig. 4.15. Identification result according to SNR (a) k-NN (b) Bayes (c) SVM





그림 4.16. PCA, LDA의 최적화

Fig. 4.16. Optimization of PCA, LDA

위의 결과로 보아 SVM 식별기를 사용하며, 얻어진 DB에 맞춰 PCA, LDA의 차원 수를 최적화하면 더 나은 식별 결과를 얻을 수 있음을 알 수 있다. 다음으로 앞서 설명한 SVM 식별기의 커널 함수와


파라미터를 최적화하는 과정을 설명할 것이다.

앞서 사용한 그림 4.14의 DB를 이용하였으며, 표 4.2에 나타난 SVM의 4 종류 커널 함수들에 대한 최적화를 진행하였다. 선택된 커널 함수와 그 파라미터를 설계 변수로 하여 최적화를 진행한 결과 최적의 식별 성능을 보인 커널 함수는 polynomial 함수이며, 파라미터 $c=3.93$, $d=1$ 일 때 가장 높은 식별 성능을 보였다. 그 결과는 아래의 그림 4.17과 같다.

검증용 DB를 생성하기 위하여 방위각에 따른 주파수 별 RCS 데이터에 SNR 20 dB의 잡음을 추가하였다. 그리고 측정 방위각 별로 학습 DB와의 식별을 1000회 수행하였으며, 식별 성공률을 나타낸 것이다. 커널 파라미터를 최적화 하기 전의 식별 결과를 보면, 방위각 -8° 에서 표적 2의 식별에 항상 실패하였으며, 표적 3의 경우 3개의 측정 방위각에서 약 10% 정도 실패율을 보이는 것을 볼 수 있었다. 여기서 커널 함수 최적화를 거친 후에는 모든 측정 방위각에서 식별이 성공하는 것을 확인할 수 있었다.

이와 같이 SVM 식별기가 k-NN, Bayes 식별기에 비해 잡음에 강하며, 최적화를 통해 높은 식별률을 보임을 확인하였다. 본 논문에서는 SVM 식별기를 이용한 표적 식별을 수행할 것이며, PCA, LDA 최적화와 SVM 커널 함수 최적화를 진행하여 식별 성공률을 높였다.

측정 방위각에 따른 식별 결과



최적화

측정 방위각에 따른 식별 결과




그림 4.17. 커널 함수 최적화

Fig. 4.17. Optimization of kernel function

4.3 시뮬레이션 및 실험 결과

앞서 연구한 최적의 산란점 추출 기법으로 산란점 정보를 추출한 후, 최적화된 SVM 표적 식별을 수행하여 그 결과를 확인하였다. 먼저 앞서 시뮬레이션으로 얻어진 산란점 정보를 이용한 표적 식별을 수행한 후, 실제 측정 데이터를 이용한 산란점 추출과 표적 식별을 수행하였다.

4.3.1 시뮬레이션 결과

앞서 4.1.2절에서 획득한 3종류의 비행기 표적의 산란점 정보를 이용하여 표적 식별을 수행하였다. 최적의 산란점 추출 기법으로 추출한 산란점의 경우 선택되는 관측 방위각의 수와 위치에 따라 다르게 얻어진다. 그러므로 여러 번의 산란점 추출을 수행한 후 데이터베이스를 구축하였다. 개별 표적마다 임의의 12 개의 관측 방위각의 수신 신호로부터의 산란점 추출 알고리즘을 30번 수행하고 홀드아웃 검증을 위해 홀수 번째 데이터 15개를 학습용으로 사용하였으며, 짝수 번째 데이터 15개를 검증용으로 사용하였다.

SVM의 성능은 PCA, LDA 차원 수에 따라 달라지며, 선택하는 커널 함수와 파라미터에 영향을 받는다. 본 논문에서는 RBF 커널 함수를 사용하였으며, 아래의 수식과 같이 PCA, LDA 차원수와 커널 함수 파라미터를 최적화하였다. n_{PCA}, n_{LDA} 는 각각 PCA, LDA의 차원수를 나타내며, γ, σ 는 표 4.2에 나타난 RBF 커널 함수의 파라미터이다. M은 검증에 사용된 데이터의 수를 나타내며, δ_i 는 i 번째 검증용 데이터로 SVM 식별을 100번 수행하여 얻어진 식별 성공률을 나타낸다.

$$f(n_{PCA}, n_{LDA}, \gamma, \sigma) = \min \left\{ - \sum_{i=1}^M \delta_i(n_{PCA}, n_{LDA}, \gamma, \sigma) \right\} \quad (4.8)$$

표 4.3는 사용된 유전 알고리즘의 파라미터를 나타낸 것이며, 그림 4.18은 수렴 곡선을 나타낸 것이다. 7세대만에 수렴하는 것을

확인하였다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 10, n_{LDA} = 7$ 이 선택되었으며, 커널 파라미터는 $\gamma = 0.2511, \sigma = 1.1546$ 으로 설정되었다. 그림 4.19와 4.20은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

표 4.3. 유전 알고리즘의 파라미터

Table 4.3. Parameters of Genetic algorithm

인구 수	50
세대 수	50
설계변수	4 ($n_{PCA}, n_{LDA}, \gamma, \sigma$)
탐색 영역	$2 \leq n_{PCA} \leq 30,$ $2 \leq n_{LDA} \leq 30,$ $10^{-9} \leq \gamma \leq 10,$ $10^{-9} \leq \sigma \leq 10$
허용 오차	0.001




그림 4.18. 수렴 곡선

Fig. 4.18. Convergence curve




그림 4.19. 추출된 특징점(PCA)
Fig. 4.19. Extracted feature(PCA)




그림 4.20. 추출된 특징점(PCA+LDA)
Fig. 4.20. Extracted feature(PCA+LDA)

그림 4.19는 PCA를 통해 데이터가 축소된 결과로 클래스 2와 3의 데이터들이 어느 정도 가까워 분류에 실패할 수 있음을 볼 수 있다. 그림 4.20은 PCA, LDA 모두 수행한 후 결과로 데이터들의 구별성이 향상된 것을 확인할 수 있다. 이렇게 추출된 특징점을 이용하여 최적화된 파라미터를 사용한 SVM 표적 식별을 수행한 결과는 그림 4.21과 같이 나타났다. 각 클래스 별로 15개의 검증데이터를 사용하여 식별을 수행하였다. 식별 결과를 confusion 매트릭스로 나타낸 것으로, 행렬의 각 열은 실제 클래스를 나타내며 행렬의 각 행은 예측된 클래스를 나타낸다. 행렬의 값은 검증 데이터의 수이다[88]. 예를 들어 그림 4.21에서 좌상단의 검정색으로 표기된 부분은 표적 1의 데이터가 입력되었을 때, 표적 1로 예측된 검증 데이터가 15개라는 의미이다. 즉, 대각원소들은 식별이 성공적으로 이루어진 데이터의 수를 나타내며, 나머지 부분은 잘못 식별된 데이터를 나타낸다. 아래의 결과를 보아, 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다. 또한 잡음의 영향을 분석하기 위하여 검증용 데이터에 화이트 가우시안 잡음을 추가하여 식별 결과를 비교하였다. SNR을 0~40 dB까지 5 dB 간격으로 100번 시행한 성공률을 정리한 결과가 아래의 그림 4.22에 나타나 있다.

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.21. 식별 결과(시뮬레이션)

Fig. 4.21. Identification result (Simulation)

그림 4.22(a)는 12개의 관측각 데이터만 이용하여 얻어진 SAR 영상을 이용한 식별 결과이며, 그림 4.22(b)는 12개의 관측각 데이터에 향상된 OMP만 적용하여 추출된 산란점을 이용한 식별 결과이고, 그림 4.22(c)는 향상된 OMP에 추가로 최적화도 수행하여 추출된 산란점을 이용한 표적 식별 결과이다. 향상된 OMP와 최적화를 수행하여 얻어진 산란점 정보를 이용한 표적 식별 결과가 잡음에 더 강한 것을 확인할 수 있다.

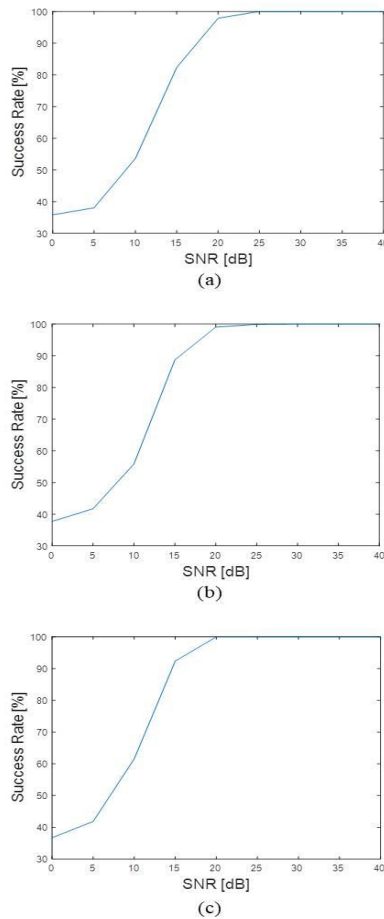


그림 4.22. 잡음에 따른 식별 성공률 (a) SAR (b) 향상된 OMP (c) 향상된 OMP+최적화

Fig. 4.22. Identification success rate according to noise (a) SAR (b) Improved OMP (c) Improved OMP+optimization

4.3.2 측정 실험 결과

실제 측정 데이터를 획득하여 산란점 추출과 표적 식별을 수행하였다. 표 4.4은 실험 환경을 나타낸 것이다. 2개의 X-band용 스탠다드 혼 안테나와 벡터 네트워크 분석기(VNA : Vector Network Analyzer)를 이용하여 신호를 송수신하였으며, 표적의 방위각을 조절하기 위한 로테이터, VNA로부터 신호를 수신하고 로테이터를 제어하기 위한 PC로 실험 환경을 구성하였다[89-91]. 그림 4.23은 레이더 측정 시스템을 나타낸 것으로, 2개의 혼 안테나를 VNA에 연결하였으며, 송신 출력 5dBm, 8~12 GHz 주파수에 801개의 주파수 샘플링으로 측정하고, 측정된 데이터는 PC로 저장된다. 방위각 별로 데이터를 측정하기 위하여 표적을 회전시킬 수 있는 로테이터를 그림 4.24와 같이 구성하였다. 스텝모터 위에 측정하려는 표적을 올려두고 PC를 시리얼 통신을 이용하여 제어하였다. 표적과 안테나 사이의 거리는 4 m로 두었으며, 표적과 안테나의 높이는 1 m이다. 그림 4.25는 측정에 사용된 표적을 나타낸 것으로, 비행기 모델의 축소 모형에 전도성 도료인 실버 페이스트를 도포하였다. 측정 표적들의 크기는 표 4.1의 모델 크기와 동일하다.

표 4.4. 실험 환경

Table 4.4. Experiment environment

안테나	X-band(8~12 GHz)용 Standard Gain 혼 안테나, 20dBi
Vector Network Analyzer	Agilent 사의 8720ES, 송신 출력 5dBm, 8~12 GHz, 801 개 주파수
로테이터	Autonics 사의 A200K-M599-G10 스텝 모터, MD5-HF14 모터 드라이브, PMC-1HS 모션 컨트롤러




그림 4.23. 레이더 측정 시스템

Fig. 4.23. Radar measurement system



그림 4.24. 로테이터

Fig. 4.24. Rotator



(a)



(b)




(c)


그림 4.25. 측정 표적 (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.25. Measured target (a) A-380 (b) Eurofighter (c) F-15


8~12 GHz 주파수에 801개의 주파수 샘플링, 방위각 $-60^{\circ} \sim 60^{\circ}$ (1° 간격)에 대하여 각 표적 별로 측정을 진행하였다. 본 논문에서는 공수 레이더로 다가오는 비행 표적의 경우 앞 부분의 일부 방위각만 측정이 가능할 거라 두고 위와 같이 방위각을 설정하였다. 측정된 데이터를 HRRP로 나타낸 결과가 그림 4.26에 나타나 있다. 그림 4.6의 시뮬레이션 결과와 어느 정도 유사하나, 오차도 어느 정도 존재하는 것을 확인할 수 있다.



(a)



(b)



(c)

그림 4.26. 측정 표적의 HRRP (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.26. HRRP of measured target (a) A-380 (b) Eurofighter (c) F-15


좀 더 정확한 표적의 형태를 보기 위해 방위각 121개의 데이터로 복원된 SAR 영상의 결과가 그림 4.27~4.29에 나타나 있다. 그림 4.7의 시뮬레이션 데이터를 이용한 SAR 영상 결과와 다르게 나타나는 것을 확인할 수 있다. 이는 표적의 정확한 고각과 방위각 설정이 어려우며, 전도성 도료의 도포 상태에 따른 문제로 보이며, 측정된 데이터를 기준으로 표적 식별을 진행하였다.

먼저 산란점 추출 알고리즘을 수행하였다. 12 개의 방위각에 대하여 향상된 OMP 알고리즘을 이용한 산란점 추출을 수행하였는데 그림 4.30에 그 결과가 나타나 있다. 기존의 SAR 영상과 비교해 보면 산란점 정보의 오차가 큰 것을 확인할 수 있다.

획득한 산란점 정보에 혼합 유전 알고리즘 기반의 산란점 추출 알고리즘을 적용하면 그림 4.31의 결과를 획득할 수 있다. SAR 영상에서 크게 보이는 산란점의 정보가 어느 정도 일치하는 것을 확인할 수 있으며, 그림 30에 비해 SAR 영상과의 오차가 많이 줄어들었다.



(a)




(b)

그림 4.27. A-380 (a) 실제 표적 (b) SAR 영상

Fig. 4.27. A-380 (a) Actual target (b) SAR image



(a)




(b)

그림 4.28. Eurofighter (a) 실제 표적 (b) SAR 영상
Fig. 4.28. Eurofighter (a) Actual target (b) SAR image



(a)



(b)

그림 4.29. F-15 (a) 실제 표적 (b) SAR 영상

Fig. 4.29. F-15 (a) Actual target (b) SAR image






그림 4.30. 추출된 산란점 (향상된 OMP, 12개의 관측 방위각) (a) A-380
(b) Eurofighter (c) F-15

Fig. 4.30. Extracted scattering center (Improved OMP, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15






그림 4.31. 추출된 산란점 (향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.31. Extracted scattering center (Improved OMP+optimization, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

측정 데이터로부터 얻은 산란점 정보를 이용하여 표적 식별을 수행하였다. 개별 표적마다 임의의 12 개의 관측 방위각의 수신 신호로부터의 산란점 추출 알고리즘을 30번 수행하고 홀드아웃 검증을 위해 홀수 번째 데이터 15개를 학습용으로 사용하였으며, 짝수 번째 데이터 15개를 검증용으로 사용하였다. 다음으로 PCA, LDA, 커널 함수 파라미터 최적화를 수행한 결과는 다음과 같았다. 유전 알고리즘의 파라미터는 표4.4와 동일하게 설정하였다. 그림 4.32는 수렴 곡선을 나타낸 것으로 13 세대에 수렴하는 것을 볼 수 있다. PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 14, n_{LDA} = 3$ 이 선택되었으며, 커널 파라미터는 $\gamma = 0.8766, \sigma = 7.4804$ 로 설정되었다. 그림 4.33과 4.34는 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

이와 같이 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.35와 같이 나타났다. 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.32. 수렴 곡선(12개의 관측 방위각)

Fig. 4.32. Convergence curve(12 observation azimuth angles)




그림 4.33. 추출된 특징점 (PCA, 12개의 관측 방위각)

Fig. 4.33. Extracted feature (PCA, 12 observation azimuth angles)




그림 4.34. 추출된 특징점 (PCA+LDA, 12개의 관측 방위각)

Fig. 4.34. Extracted feature (PCA+LDA, 12 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.35. 식별 결과(실험, 12개의 관측 방위각)

Fig. 4.35. Identification result(experiment, 12 observation azimuth angles)

선택되는 방위각의 수에 따라서 얻어지는 산란점 정보의 정확도가 달라지므로, 6개의 관측 방위각일 때의 식별 결과를 확인해 보았다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 11, n_{LDA} = 2$ 이 선택되었으며, 커널 파라미터는 $\gamma = 5.30201$ $\sigma = 9.7508$ 로 설정되었다. 그림 4.36과 4.37은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

이와 같이 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.38과 같이 나타났다. 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.36. 추출된 특징점(PCA, 6개의 관측 방위각)

Fig. 4.36. Extracted feature(PCA, 6 observation azimuth angles)




그림 4.37. 추출된 특징점(PCA+LDA, 6개의 관측 방위각)

Fig. 4.37. Extracted feature(PCA+LDA, 6 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.38. 식별 결과(실험, 6개의 관측 방위각)

Fig. 4.38. Identification result(experiment, 6 observation azimuth angles)

다음으로 3개의 관측 방위각일 때의 식별 결과를 확인해 보았다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 20, n_{LDA} = 3$ 이 선택되었으며, 커널 파라미터는 $\gamma = 4.1832$ $\sigma = 2.4408$ 로 설정되었다. 그림 4.39와 4.40은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다. 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.41과 같이 나타났다. 방위각의 수가 줄어도 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.39. 추출된 특징점 (PCA, 3개의 관측 방위각)

Fig. 4.39. Extracted feature (PCA, 3 observation azimuth angles)




그림 4.40. 추출된 특징점 (PCA+LDA, 3개의 관측 방위각)


Fig. 4.40. Extracted feature (PCA+LDA, 3 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		


그림 4.41. 식별 결과(실험, 3개의 관측 방위각)

Fig. 4.41. Identification result(experiment, 3 observation azimuth angles)


SVM 최적화의 성능과 잡음에 대한 영향을 분석하기 위하여 관측 방위각 12, 6, 3일 때의 SNR에 따른 식별 성공률을 비교해 보았다. 그 결과는 아래의 그림 4.42와 그림 4.43과 같다. 그림 4.42는 SVM 최적화 전의 식별 결과이다. $n_{PCA} = 11, n_{LDA} = 11$ 이 선택되었으며, rbf 커널의 파라미터는 $\gamma = 1, \sigma = 1$ 로 설정하였다. 그림 4.43은 SVM 최적화 후의 식별 결과로 PCA, LDA의 차원수와 커널 파라미터는 앞선 방위각 12, 6, 3일 때의 식별에서 선택된 파라미터와 동일하게 설정되었다. SVM 최적화를 한 후의 식별 성능이 월등히 뛰어난 것을 볼 수 있다. 잡음에 대한 성능의 경우, 관측 방위각을 적게 선택할수록 식별 성능이 떨어지지만 SNR 20dB까지는 식별이 잘 이루어지는 것을 확인할 수 있다.



(a)




(b)




(c)

그림 4.42. 잡음에 따른 식별 성공률(SVM 최적화 전) (a) 12개의 관측 방위각 (b) 6개의 관측 방위각 (c) 3개의 관측 방위각


Fig. 4.42. Identification success rate according to noise(before SVM optimization) (a) 12 observation azimuth angles (b) 6 observation azimuth angles (c) 3 observation azimuth angles



(a)



(b)



(c)

그림 4.43. 잡음에 따른 식별 성공률(SVM 최적화 후) (a) 12개의 관측 방위각 (b) 6개의 관측 방위각 (c) 3개의 관측 방위각

Fig. 4.43. Identification success rate according to noise(after SVM optimization) (a) 12 observation azimuth angles (b) 6 observation azimuth angles (c) 3 observation azimuth angles

제 5 장 결론 및 향후 연구 계획

5.1 결론

본 논문에서는 레이더 표적 식별에서 식별 성능에 가장 큰 영향을 주는 특징점 추출 단계에 표적의 산란점 정보를 사용하는 것을 제안하였다. 산란점 정보를 추출하는데 있어, 관측각의 수가 많을수록 보다 정확한 산란점 정보를 획득할 수 있는데, 공대공 표적 식별의 경우, 레이더 표적으로부터 얻을 수 있는 관측각의 데이터는 제한적이다. 그러므로 기존의 데이터보다 더 적은 측정 데이터로도 원본 데이터와 유사한 데이터를 복원할 수 있는 압축 센싱 기법과 최적화 알고리즘을 결합하여 기존의 산란점 추출 방법보다 더 정확하며 연산 속도의 저하를 줄일 수 있는 최적의 산란점 추출 기법을 제안하였다.

본 논문에서는 기존의 CS 알고리즘 중 하나인 OMP 알고리즘에서 변형된 연산 속도가 향상된 OMP 알고리즘을 제시하고 산란점 추출 문제에 적용하여 검증하였다. 기존의 OMP 알고리즘에 비해 약 81%의 연산 시간을 줄일 수 있었으며, 적은 관측각의 데이터만으로도 기존의 BPA 영상과 유사한 산란점 정보를 얻을 수 있었다. 또한, 향상된 OMP로 기존의 OMP에 비해 81.2%의 연산 시간을 줄일 수 있음을 확인하였다. 다음으로 본 논문에서 해결하려는 산란점 추정과 같이 설계 변수가 많은 고차원 최적화 문제의 경우에 강점을 보이는 혼합 유전 알고리즘을 제시하였다. 기존의 유전 알고리즘에 나선형 교차 방식을 선택하여 고차원 문제를 잘 풀 수 있도록 하였으며, 최적 해를 잘 찾으며 수렴 속도를 증가시키기 위해 해 집단을 여러 그룹으로 나누어 각 그룹 별로 다른 교차 방식을 수행하였다. 그에 대한 검증을 위해 여러 시험 함수에 적용하였으며 기존의 알고리즘과의 비교를 수행하여, 기존의 다른 최적화 알고리즘에 비해 고차원 문제를

해결하는데 더 좋은 성능을 보임을 확인하였다. 검증을 위해 산란점 추출 문제에 적용하여 산란점 정보를 잘 추출되는 것을 확인하였다.

앞서 제시한 향상된 OMP 알고리즘과 혼합 유전 알고리즘을 결합하여 최적의 산란점 추출 기법을 제시하였다. 적은 데이터로도 원본 데이터와 유사한 정보를 얻을 수 있는 향상된 OMP 알고리즘을 이용하여 산란점 정보를 추출한 후, 추출된 산란점 정보를 혼합 유전 알고리즘의 초기해로 하여 최적화를 수행하여 수렴속도를 향상시켰다. 기존의 임의의 초기 해를 이용한 최적화에 비해, 64.87%의 연산 시간이 줄어든 것을 확인할 수 있었다. 또한, 향상된 OMP를 이용한 산란점 추출의 경우 임의로 샘플링되는 관측 방위각에 따라 산란점 정보가 제대로 추출되지 못하는 경우가 발생한다. 이러한 문제를 최적화를 통한 보상으로 해결할 수 있다. 최적의 산란점 추출 기법을 검증하기 위하여 3종류의 비행기 표적의 수신 신호를 PO를 이용하여 획득한 후, 실제 이미징 결과에서 보이는 산란점 정보와 비교하였다. 그 결과 산란점 추출이 제대로 이루어짐을 확인하였다.

실제 실험에 적용하기 위하여 금속도료로 도포한 3종류의 모형 비행기를 X-band의 레이더 측정 시스템을 이용하여 측정하였다. 수신된 신호를 최적의 산란점 추출 기법을 적용하여 산란점 정보를 획득하였으며, 획득한 산란점 정보를 특징점으로 두고 표적 식별을 수행하였다. PCA와 LDA를 적용하여 특징점 정보를 압축하고 구별성을 높였으며, SVM 식별기를 이용하여 표적 식별을 수행하였다. 식별 성능의 향상을 위해 PCA, LDA의 차원수와 SVM의 커널 함수를 얻어진 DB에 맞게 최적화하여 식별 성능을 향상시켰다. 그 결과 3종류의 표적을 모두 잘 식별하는 것을 확인하였다.

이와 같이 표적 식별에서 획득할 수 있는 표적의 관측 방위각은 제한적이기에 추출된 산란점 정보의 정확성이 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 산란점 추출 기법을 적용하면 보다 정확하게 표적을 식별하는데 도움이 될 것으로 보인다.

5.2 향후 연구 계획

레이더 수신 신호의 경우 표적으로부터 수신되는 신호 외에도 다중 경로에 의한 반사 신호와 클러터에 의한 신호도 함께 수신된다. 수치해석 기법을 활용하거나, 실제 측정으로 다중 경로에 의한 신호를 고려할 수 있지만, 클러터 환경을 모델링하거나 측정하는 것은 어려운 일이다. 본 논문에서는 표적으로 비행기를 선택하여 클러터의 영향이 크지 않았지만, 해상 환경과 같이 클러터의 영향이 큰 상황에서는 클러터의 억제 혹은 클러터 모델링에 대한 추가 연구가 필요하다. 그리고 실제 클러터 환경에서의 측정 및 표적 식별에 대한 연구가 필요할 것으로 보인다.

참고 문헌

- [1] NG, Saab Gripen, “Dynamics of the Saab Group,”
- [2] Gurdal, Armagan, et al, “A High Gain and High Efficiency 15 W X-Band GaN Power Amplifier MMIC,” 2019 European Microwave Conference in Central Europe (EuMCE), IEEE, 2019.
- [3] Anderson, Stuart J, “Target classification, recognition and identification with HF radar,” Proceedings of the NATO Research and Technology Agency. Sensors and Electronics Technology Panel Symposium SET-080 / RSY17 / RFT : “Target identification and recognition using RF systems”, RTO-MP-SET, 2004.
- [4] 최인식, “레이더 표적인식 기술동향 및 전망,” 한국정보통신학회지, vol. 13, no. 2, pp. 34-40.
- [5] Lee, Kun-Chou, Chih-Wei Huang, and Ming-Chung Fang, “Radar target recognition by projected features of frequency-diversity RCS,” Progress In Electromagnetics Research, vol. 81, pp. 121-133, 2008.
- [6] D. Blacknell, H. Griffiths, “Radar Automatic Target Rrecognition(ATR) and Non-Cooperative Target Recognition(NCTR),” The Institution of Engineering and Technology London. UK, 2013.
- [7] C.M. Pilcher and A. Khotanzad, “Maritime ATR using Classifier Combination and High Resolution Range Profiles,” IEEE Trans. on aerospace and electronic systems, vol. 47, no. 4, pp. 2558-2573.
- [8] 최인오, and 박상홍, “다중각도 거리측면도를 이용한 효율적인 차량식별 연구,” 한국정보기술학회논문지, vol. 11, no. 6, pp. 9-16, 2013.
- [9] 최인오, 주문갑 and 박상홍, “거리측면도를 이용한 효율적인 차량식별 요인 및 레이더 규격 연구,” 한국정보기술학회논문지, vol. 10, no. 7, pp. 153-160, 2012.
- [10] Li, Wenchao, Boli Xiong, and Gangyao Kuang, “Target classification and recognition based on micro-Doppler radar signatures.” 2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL), IEEE, 2017.
- [11] Jianxiong, Zhou, et al, “Automatic target recognition of SAR images based on global scattering center model,” IEEE transactions on Geoscience and remote sensing, vol. 49, no. 10, pp. 3713-3729, 2011.
- [12] Liu, Hongwei, et al, “Attributed scattering center extraction algorithm based on sparse representation with dictionary refinement,” IEEE Transactions on Antennas and Propagation, vol. 65, no. 5, pp. 2604-

- 2614, 2017.
- [13] Zhang, Xinzheng, Jianhong Qin, and Guojun Li, "SAR target classification using Bayesian compressive sensing with scattering centers features," *Progress In Electromagnetics Research*, vol. 136, pp. 385–407, 2013.
 - [14] Fu, Yao-wen, Yu-ping Jia, and Zhao-wen Zhuang, "Radar target classification based on one dimensional scattering centers matching," *Dianzi Xuebao(Acta Electronica Sinica)*, vol. 34, no. 3, pp. 404–408, 2006.
 - [15] Koets, Michael A., and Randolph L. Moses, "Feature extraction using attributed scattering center models on SAR imagery," *Algorithms for Synthetic Aperture Radar Imagery VI*, vol. 3721, International Society for Optics and Photonics, 1999.
 - [16] Konovaluk, Maxim, Yury Kuznetsov, and Andrey Baev, "Point scatterers target identification using frequency domain signal processing," *2008 International Radar Symposium, IEEE*, 2008.
 - [17] Karlina, Riafeni, *Compressive Sensing Applied to High Resolution Imaging by Synthetic Aperture Radar*, Ph.D. dissertation, Tohoku University, Japan, Aug. 2013.
 - [18] Jung, Sang-Hoon, et al, "High-resolution millimeter-wave ground-based SAR imaging via compressed sensing," *IEEE Transactions on Magnetism*, vol. 54, no. 3, pp. 1–4, 2017.
 - [19] Chen, Xudong, "Subspace-based optimization method for solving inverse-scattering problems," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 1, pp. 42–49, 2010.
 - [20] Rocca, Paolo, et al, "Evolutionary optimization as applied to inverse scattering problems," *Inverse Problems*, vol. 25, no. 12, p. 123003, 2009.
 - [21] Oliveri, Giacomo, et al, "Multiresolution subspace-based optimization method for inverse scattering problems," *JOSA A*, vol. 28, no. 10, pp. 2057–2069, 2011.
 - [22] Mirjalili, Seyedali, and Andrew Lewis, "The whale optimization algorithm," *Advances in Engineering Software*, vol. 95, pp. 51–67, 2016.
 - [23] Mafarja, Majdi M., and Seyedali Mirjalili, "Hybrid Whale Optimization Algorithm with simulated annealing for feature selection," *Neurocomputing*, vol. 260, pp. 302–312, 2017.
 - [24] Askarzadeh, Alireza, "Bird mating optimizer: an optimization algorithm

- inspired by bird mating strategies,” *Communications in Nonlinear Science and Numerical Simulation*, vol. 19, no. 4, pp. 1213–1228, 2014.
- [25] Askarzadeh, Alireza, and Alireza Rezazadeh, “Extraction of maximum power point in solar cells using bird mating optimizer–based parameters identification approach,” *Solar energy*, vol. 90, pp. 123–133, 2013.
- [26] Frigui, Hichem, and Paul Gader, “Detection and discrimination of land mines in ground–penetrating radar based on edge histogram descriptors and a possibilistic k–nearest neighbor classifier,” *IEEE Transactions on Fuzzy Systems*, vol. 17, no. 1, pp. 185–199, 2008.
- [27] Rish, Irina, “An empirical study of the naive Bayes classifier,” *IJCAI 2001 workshop on empirical methods in artificial intelligence*, vol. 3, no. 22, 2001.
- [28] 강운정, 이종현, 배진호, 이재일, 권지훈, 이노복 and 안미림, “SVM 기반 결정 트리 구조를 이용한 목표물 식별 알고리즘,” *대한전자공학회 학술대회*, pp. 497–500, 2012.
- [29] Walter, G. Carrara, S. Goodman Ron, and M. Majewski Ronald, *Spotlight Synthetic Aperture Radar: Signal Processing Algorithms*, Artech House, 1995.
- [30] Wang, Bu–Chin, *Digital signal processing techniques and applications in radar image processing*, vol. 91, John Wiley & Sons, 2008.
- [31] Briggs, William L., and Van Emden Henson, *The DFT: an owner's manual for the discrete Fourier transform*, Society for Industrial and Applied Mathematics, 1995.
- [32] D. R. Wehner, *High Resolution Radar*, 2nd ed., pp. 197–237, Artech House, Boston, 1995.
- [33] Vidhya, K, “Medical Image Compression using Adaptive Subband Threshold,” *Journal of Electrical Engineering and Technology*, vol. 11, no. 2, pp. 499–507, 2016.
- [34] Jideani, Josiah, and Andrew Wilkinson, “Air–based synthetic aperture sonar tomography using compressive sensing,” *2014 IEEE International Ultrasonics Symposium*, IEEE, 2014.
- [35] Ender, Joachim HG, “On compressive sensing applied to radar,” *Signal Processing*, vol. 90, no. 5, pp. 1402–1414, 2010.
- [36] Candès, Emmanuel J., and Michael B. Wakin, “An introduction to compressive sampling,” *IEEE signal processing magazine*, vol. 25, no. 2, pp. 21–30, 2008.
- [37] Tropp, Joel A., and Anna C. Gilbert, “Signal recovery from random

- measurements via orthogonal matching pursuit,” *IEEE Transactions on information theory*, vol. 53, no. 12, pp. 4655–4666, Dec. 2007.
- [38] Needell, Deanna, and Joel A. Tropp, “CoSaMP: Iterative signal recovery from incomplete and inaccurate samples,” *Applied and computational harmonic analysis*, vol. 26, no. 3, pp. 301–321, 2009.
- [39] Tipping, Michael E, “The relevance vector machine,” *Advances in neural information processing systems*, 2000.
- [40] Hughes, Thomas JR, Leopoldo P. Franca, and Gregory M. Hulbert, “A new finite element formulation for computational fluid dynamics: VIII. The Galerkin/least-squares method for advective-diffusive equations,” *Computer methods in applied mechanics and engineering*, vol. 73, no. 2, pp. 173–189, 1989.
- [41] Nussbaumer, Henri J, “The fast Fourier transform,” *Fast Fourier Transform and Convolution Algorithms*, Springer, Berlin, Heidelberg, pp. 80–111, 1981.
- [42] Yigit, Enes, et al, “Short-range ground-based synthetic aperture radar imaging: performance comparison between frequency-wavenumber migration and back-projection algorithms,” *Journal of Applied Remote Sensing*, vol. 7, no. 1, pp. 073483–073483, 2013.
- [43] Yegulalp, Ali F, “Fast backprojection algorithm for synthetic aperture radar,” *Proceedings of the 1999 IEEE Radar Conference, Radar into the Next Millennium (Cat. No. 99CH36249)*, IEEE, 1999.
- [44] Nocedal, Jorge, and Stephen J. Wright, “Conjugate gradient methods,” *Numerical optimization*, pp. 101–134, 2006.
- [45] Battiti, Roberto, “First- and second-order methods for learning: between steepest descent and Newton's method,” *Neural computation* vol. 4, no. 2, pp. 141–166, 1992.
- [46] Ruder, Sebastian, “An overview of gradient descent optimization algorithms,” *arXiv preprint arXiv:1609.04747*, 2016.
- [47] Weicker, Karsten, and Nicole Weicker, “On evolution strategy optimization in dynamic environments,” *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, vol. 3, IEEE, 1999.
- [48] Whitley, Darrell, “A genetic algorithm tutorial,” *Statistics and computing*, vol. 4, no. 2, pp. 65–85, 1994.
- [49] Gudla, Pradeep Kumar, and Ranjan Ganguli, “An automated hybrid genetic-conjugate gradient algorithm for multimodal optimization problems,” *Applied Mathematics and Computation*, vol. 167, no. 2, pp.

- 1457–1474, 2005.
- [50] Michael, W., and J. N. Siddall, “The optimization problem with optimal tolerance assignment and full acceptance,” pp. 842–848, 1981.
 - [51] Kwon, Hyuk–Sung, Jong–Suk Ro, and Hyun–Kyo Jung, “A novel social insect optimization algorithm for the optimal design of an interior permanent magnet synchronous machine,” *IEEE Transactions on Magnetics*, vol. 54, no. 12, pp. 1–6, 2018
 - [52] Molga, Marcin, and Czesław Smutnicki, “Test functions for optimization needs,” *Test functions for optimization needs*, vol. 101, 2005.
 - [53] Giusfredi, Giovanni, *Physical optics: concepts, optical elements, and techniques*, Springer, 2019.
 - [54] B. Li, G.J. Zhang and Y. Wang, “Application of MoM–PO Hybrid Technique in Complex Target High Resolution Imaging Simulation,” *IET International Radar Conference*, 2009.
 - [55] Jakowatz, Charles VJ, et al. *Spotlight–mode synthetic aperture radar: a signal processing approach: a signal processing approach*, Springer Science & Business Media, 2012.
 - [56] Beckmann, Matthias, and Armin Iske, “Error estimates for filtered back projection.” *2015 International Conference on Sampling Theory and Applications (SampTA)*, IEEE, 2015.
 - [57] Shlens, Jonathon, “A tutorial on principal component analysis,” *arXiv preprint arXiv:1404.1100*, 2014.
 - [58] Jolliffe, Ian T., and Jorge Cadima, “Principal component analysis: a review and recent developments,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 374.2065, p. 20150202, 2016.
 - [59] Tharwat, Alaa, et al, “Linear discriminant analysis: A detailed tutorial,” *AI communications*, vol. 30, no. 2, pp. 169–190, 2017.
 - [60] Lee, K–C., and J–S. Ou, “Radar target recognition by using linear discriminant algorithm on angular–diversity RCS,” *Journal of Electromagnetic Waves and Applications*, vol. 21, no. 14, pp. 2033–2048, 2007.
 - [61] Barnouti, Nawaf Hazim, et al, “Face Detection and Recognition Using Viola–Jones with PCA–LDA and Square Euclidean Distance,” *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 7, no. 5, pp. 371–377, 2016.
 - [62] Gou, Jianping, et al, “A new distance–weighted k–nearest neighbor

- classifier,” *J. Inf. Comput. Sci*, vol. 9, no. 6, pp. 1429–1436, 2012
- [63] Sohail, Abu Sayeed Md, and Prabir Bhattacharya, “Classification of facial expressions using k-nearest neighbor classifier,” *International Conference on Computer Vision/Computer Graphics Collaboration Techniques and Applications*. Springer, Berlin, Heidelberg, 2007.
- [64] Duda, R. O., P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd edition, John Wiley & Sons Inc., 2001.
- [65] Sebe, Nicu, et al, “Emotion recognition using a cauchy naive bayes classifier,” *Object recognition supported by user interaction for service robots*, vol. 1, IEEE, 2002.
- [66] Mukherjee, Saurabh, and Neelam Sharma, “Intrusion detection using naive Bayes classifier with feature reduction,” *Procedia Technology*, vol. 4, pp. 119–128, 2012.
- [67] LI, Jing-hua, Jia-dong XU, and Hong-juan LI, “Research on Helicopter Target Identification based on Support Vector Machine [J],” *Fire Control and Command Control*, vol. 1, 2008.
- [68] Kent, S., N. G. Kasapoglu, and M. Kartal, “Radar target classification based on support vector machines and high resolution range profiles,” *2008 IEEE Radar Conference*. IEEE, 2008.
- [69] Kim, Youngwook, and Hao Ling, “Human activity classification based on micro-Doppler signatures using a support vector machine,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 5, pp. 1328–1337, 2009.
- [70] Liu, Liang, et al, “Fall detection using doppler radar and classifier fusion,” *Proceedings of 2012 IEEE-EMBS International Conference on Biomedical and Health Informatics*, IEEE, 2012.
- [71] Suykens, Johan AK, and Joos Vandewalle, “Least squares support vector machine classifiers,” *Neural processing letters*, vol. 9, no. 3, pp. 293–300, 1999.
- [72] Cauwenberghs, Gert, and Tomaso Poggio, “Incremental and decremental support vector machine learning,” *Advances in neural information processing systems*, 2001.
- [73] Bufler, Travis D., and Ram M. Narayanan, “Radar classification of indoor targets using support vector machines,” *IET Radar, Sonar & Navigation*, vol. 10, no. 8, pp. 1468–1476, 2016.
- [74] 이강인, 다중 HRRP 기반 표적 산란점 추정 및 식별 연구, 공학박사 학위논문, 광운대학교, 2018.
- [75] Nguyen, Loc, “Tutorial on support vector machine,” *Applied and*

- Computational Mathematics 6.4–1 pp. 1–15, 2017.
- [76] Bertsekas, Dimitri P, Constrained optimization and Lagrange multiplier methods, Academic press, 2014.
 - [77] Best, Michael J, Quadratic programming with computer programs, CRC Press, 2017.
 - [78] Doucet, Jean–Pierre, et al, “Nonlinear SVM approaches to QSPR /QSAR studies and drug design,” Current Computer–Aided Drug Design vol. 3, no. 4, pp. 263–289, 2007.
 - [79] Wang, Lipo, Support vector machines: theory and applications. vol. 177, Springer Science & Business Media, 2005.
 - [80] Hofmann, Martin, “Support vector machines–kernels and the kernel trick,” Notes, vol. 26, no. 3, 2006.
 - [81] Kung, Sun Yuan, Kernel methods and machine learning, Cambridge University Press, 2014.
 - [82] Prajapati, Gend Lal, and Arti Patle, “On performing classification using SVM with radial basis and polynomial kernel functions,” 2010 3rd International Conference on Emerging Trends in Engineering and Technology, IEEE, 2010.
 - [83] Amari, Shun–ichi, and Si Wu, “Improving support vector machine classifiers by modifying kernel functions,” Neural Networks, vol. 12, no. 6, pp. 783–789, 1999.
 - [84] Camps–Valls, Gustavo, et al, “Fuzzy sigmoid kernel for support vector classifiers,” Neurocomputing, vol. 62, pp. 501–506, 2004.
 - [85] Wu, Chih–Hung, Gwo–Hshiung Tzeng, and Rong–Ho Lin, “A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression,” Expert Systems with Applications, vol. 36, no. 3, pp. 4725–4735, 2009.
 - [86] Yang, Liu, et al. "Comparison research of single kernel and multi–kernel relevance vector machine." Computer Engineering, vol. 36, no. 12, pp. 195–197, 2010.
 - [87] Oxford, Raquel M., and Larry G. Daniel, “Basic Cross–Validation: Using the “Holdout” Method To Assess the Generalizability of Results,” Research in the Schools, vol. 8, no. 1, pp. 83–89, 2001.
 - [88] Visa, Sofia, et al, “Confusion Matrix–based Feature Selection,” MAICS, vol. 710, pp. 120–127, 2011.
 - [89] Burki, Jehanzeb, Touseef Ali, and Shahzad Arshad, “Vector network analyzer (VNA) based synthetic aperture radar (SAR) imaging,” INMIC, IEEE, 2013.

- [90] Caliskan, Alper, et al, “24 GHz short range radar system measurements for synthetic aperture radar imaging,” 2017 IEEE Microwaves, Radar and Remote Sensing Symposium (MRRS), IEEE, 2017.
- [91] Lee, Hoonyol, Younghun Ji, and Hyangsun Han, “Experiments on a ground-based tomographic synthetic aperture radar,” Remote Sensing vol. 8, no. 8, pp. 667, 2016.

Abstract

Optimal Scattering Center Extraction and Identification in Radar Target

Sang-Hoon Jung

Dept. of Electrical and Computer Engineering

The Graduate School

Seoul National University

In this paper, it is proposed to use the scattering center information of the target as a feature used in the feature extraction step that has the greatest influence on the identification performance in radar target identification. A technique combining a compressive sensing (CS) that can reconstruct data similar to the original data in case of limited measurement like air to air detection, and a high-dimensional optimization algorithm is proposed. This technique is more accurate than the conventional scattering center extraction method and can reduce a decrease in computation speed. To verify this technique, the identification using a raw data obtained through the numerical analysis method was performed. And verification was also conducted through actual measurement experiment.

First, the acquisition process and modeling of the received radar signal used for target identification was explained, and then the specific principles of the CS algorithm and the high-dimensional optimization algorithm that are the basis of the optimal scattering

center extraction algorithm presented in this paper were described.

A CS algorithm with improved computational speed, which is modified from the orthogonal matching pursuit (OMP) algorithm, which is one of the conventional CS algorithms, is presented and verified by applying it to a simple scattering center extraction problem. It was confirmed that the same scattering center information was extracted while reducing the computational time of 81.2% than the conventional OMP. Next, in this paper, we proposed a hybrid genetic algorithm that shows strength in solving high-dimensional optimization problems with many design variables, such as extraction of scattering center. Spiral crossover was selected to solve high-dimensional problems well, and in order to find an optimal solution and to increase the convergence speed, solution groups were divided into several groups, and different crossover methods were performed for each group. To verify the algorithm, it was applied to several test functions and scattering center extraction problem and compared with the conventional optimization algorithm.

In order to extract the optimal scattering point, the improved OMP algorithm and the hybrid genetic algorithm presented above were combined. First, scattering centers were extracted by applying an improved OMP algorithm to the received radar signal. More accurate scattering center information was extracted by applying the hybrid genetic algorithm using the extracted scattering center as an initial value. As a result, the increase in computational time, which is a disadvantage of the hybrid genetic algorithm, was reduced by 64.87%.

Target identification was performed using the obtained scattering center information. As an identifier, a support vector machine

(SVM) capable of optimization was used. For verification, the optimal scattering center extraction technique is applied to the simulation data and actual measurement data, and identification is performed with the SVM identifier. As a result, it was confirmed that it showed a high identification success rate even with small measurement data such as three observation azimuth angles, and it was confirmed that it was successfully identified even in a noise environment of SNR 20 dB.

The observation angle of the target that can be obtained in the identification performance is limited, and the accuracy of the acquired scattering center information is also reduced. In this limited situation, applying proposed algorithm will help to more accurately identify the target.

Keywords : Compressive Sensing, Extraction of Scattering Center, Feature Extraction, High-dimensional Optimization, Support Vector Machine, Target Identification.

Student Number : 2014-22578



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학박사 학위논문

레이더 표적에 관한 최적의 산란점 추출 및 식별

Optimal Scattering Center Extraction and
Identification in Radar Target

2020년 8월

서울대학교 대학원

전기·정보공학부

정 상 훈

레이더 표적에 관한 최적의 산란점 추출 및 식별

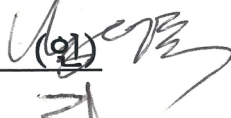




Optimal Scattering Center Extraction and
Identification in Radar Target

지도 교수 정 현 교

이 논문을 공학박사 학위논문으로 제출함
2020년 8월

서울대학교 대학원
전기·정보공학부
정 상 훈

정상훈의 박사 학위논문을 인준함
2020년 8월

위원장	남 상 욱	(인) 
부위원장	정 현 교	(인) 
위원	오 정 석	(인) 
위원	정 용 식	(인) 
위원	강 노 원	(인) 

초 록

본 논문에서는 레이더 표적 식별에서 식별 성능에 가장 큰 영향을 주는 특징점 추출 단계에 사용되는 데이터로 표적의 산란점 (Scattering Center) 정보를 사용하는 것을 제안하였으며, 공대공 탐지와 같은 제한된 측정 데이터만 얻을 수 있는 환경에서도 원본 데이터와 유사하게 복원할 수 있는 압축 센싱 (CS : Compressive Sensing)과 설계 변수가 많은 문제를 잘 해결할 수 있는 고차원 최적화 (High-dimensional Optimization) 알고리즘을 사용하여 기존의 산란점 추출 기법보다 더 정확하며 연산 속도의 저하를 줄일 수 있는 산란점 추출 알고리즘을 제안하였다. 이에 대한 검증을 위해 수치해석적 방법을 통해 얻어진 원시 데이터에 대한 식별 성능을 확인하였으며, 실제 측정 실험을 통해 검증을 수행하였다.

먼저 표적 식별에 사용되는 레이더 수신 신호를 획득하는 과정과 모델링에 대해 설명하였으며, 다음으로 본 논문에서 제시하는 최적의 산란점 추출 알고리즘의 기반이 되는 CS 알고리즘과 고차원 최적화 알고리즘에 대한 구체적인 원리를 설명하였다. 기존의 CS 알고리즘 중 하나인 orthogonal matching pursuit (OMP) 알고리즘에서 연산 속도를 향상시킨 새로운 OMP 알고리즘을 제시하고 간단한 산란점 추출 문제에 적용하여 기존의 OMP보다 81.2%의 연산 시간을 줄이면서 동일한 산란점 정보를 추출하는 것을 확인하였다. 다음으로 본 논문에서 해결하려는 산란점 추출과 같이 설계 변수가 많은 고차원 최적화 문제의 경우에 강점을 보이는 혼합 유전 알고리즘 (Hybrid Genetic Algorithm)을 제시하였다. 나선형 교차 방식을 선택하여 고차원 문제를 잘 풀 수 있도록 하였으며, 최적 해를 잘 찾으며 수렴 속도를 증가시키기 위해 해 집단을 여러 그룹으로 나누어 각 그룹 별로 다른 교차 방식을 수행하였다. 그에 대한 검증을 위해 여러 시험 함수와 산란점 추출 문제에 적용하였으며 기존의 최적화 알고리즘과의 비교를 수행하여 제안한 알고리즘이 고차원 문제를 해결하는데 가장

뛰어남을 보였다.

최적의 산란점을 추출하기 위해 앞서 제시한 향상된 OMP 알고리즘과 혼합 유전 알고리즘을 결합하였다. 먼저 레이더 수신 신호에 향상된 OMP 알고리즘을 적용하여 산란점을 추출하였다. 추출된 산란점 정보를 초기값으로 하여 혼합 유전 알고리즘을 적용하여 보다 정확한 산란점 정보를 추출하였으며, 혼합 유전 알고리즘의 단점인 연산 시간의 증가를 64.87% 줄일 수 있었다.

획득한 산란점 정보를 이용하여 표적 식별을 수행하였는데, 식별기로 최적화가 가능한 서포트 벡터 머신 (SVM : Support Vector Machine)을 이용하였다. 검증을 위해 시뮬레이션 데이터와 실제 측정 데이터에 앞서 제시한 최적의 산란점 추출 기법을 적용하고, 최적화된 SVM을 이용한 식별 성능을 확인해 보았다. 그 결과, 3개의 관측 방위각과 같이 적은 측정 데이터에도 높은 식별 성공률을 보임을 확인할 수 있었으며, SNR 20dB의 잡음 환경에서도 성공적으로 식별됨을 확인하였다.

식별 수행에서 획득할 수 있는 표적의 관측각은 제한적이며, 획득한 산란점 정보의 정확성도 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 알고리즘을 적용하면 보다 정확하게 표적을 식별하는데 도움이 될 것으로 보인다.

주요어 : 압축 센싱 (Compressive Sensing), 산란점 추출 (Extraction of Scattering Center), 특징점 추출 (Feature Extraction), 고차원 최적화 (High-dimensional Optimization), 서포트벡터머신 (Support Vector Machine), 표적 식별 (Target Identification).

학 번 : 2014-22578

목 차

국문 초록	i
목 차	iii
그림 목차	v
표 목차	vii
기호 및 약어 설명	viii
제 1 장 서 론	1
1.1 연구의 배경	1
1.2 논문 구성	8
제 2 장 레이더 수신 신호 모델링	10
2.1 수신 신호 모델링	10
2.2 시뮬레이션 결과	13
제 3 장 최적의 산란점 추출 알고리즘	15
3.1 Compressive sensing 기반의 산란점 추출 알고리즘	15
3.1.1 Compressive sensing	15
3.1.2 향상된 CS 알고리즘	18
3.1.3 시뮬레이션 결과	20
3.2 최적화 알고리즘 기반의 산란점 추출	28
3.2.1 혼합 유전 알고리즘	29
3.2.2 시뮬레이션 결과	36
제 4 장 최적의 산란점 추출 및 식별	44
4.1 최적의 산란점 추출 기법	44
4.1.1 산란점 추출 기법	47
4.1.2 시뮬레이션 결과	51
4.2 식별 알고리즘	57
4.2.1 식별기 연구	57
4.2.2 Support vector machine을 이용한 식별	58
4.3 시뮬레이션 및 실험 결과	71
4.3.1 시뮬레이션 결과	71
4.3.2 측정 실험 결과	76
제 5 장 결론 및 향후 연구 계획	95
5.1 결론	95
5.2 향후 연구계획	97
참고문헌	98
Abstract	106

그림 목차

그림 1.1. 레이더 수신 신호.....	1
그림 1.2. 표적 식별 단계.....	2
그림 1.3. 고각, 방위각, 주파수 별로 획득한 RCS 데이터베이스	3
그림 1.4. 압축 센싱의 개념도.....	4
그림 2.1. 첩 신호.....	10
그림 2.2. 산란점의 위치.....	14
그림 2.3. 거리 프로파일.....	14
그림 3.1. OMP 알고리즘의 순서도.....	18
그림 3.2. 향상된 OMP 알고리즘의 순서도.....	19
그림 3.3. 시간 영역에서의 신호 x	20
그림 3.4. 10%의 무작위 샘플링된 신호,.....	21
그림 3.5. 향상된 OMP 알고리즘으로 획득한 성진 신호 s 의 크기	21
그림 3.6. 산란점 위치와 관측점 위치.....	24
그림 3.7. (a) 추출된 산란점(향상된 OMP) (b) 추출된 산란점 (OMP).....	25
그림 3.8. (a) 추출된 이미지(BPA, 12개의 임의의 관측 방위각) (b) 추출된 이미지(BPA, $\phi = 0 \sim 359^\circ$).....	26
그림 3.9. 유전 알고리즘의 순서도.....	29
그림 3.10. 나선형 교차.....	31
그림 3.11. 혼합 유전 알고리즘의 자식 해 생성 방법.....	34
그림 3.12. 혼합 유전 알고리즘의 순서도.....	35
그림 3.13. 혼합 유전 알고리즘의 평가를 위한 시험 함수.....	38
그림 3.14. 'A' 형태의 표적.....	41
그림 3.15. (a) WOA로 추정된 산란점 (b) BMO로 추정된 산란점 (c) 제안한 혼합 유전 알고리즘으로 추정된 산란점..	42
그림 3.16. (a) 'A' 형태의 표적 (b) 추정된 산란점 (c) 'O' 형태의 표적 (d) 추정된 산란점 (e) 'F' 형태의 표적 (f) 추정된 산란점.....	43
그림 4.1. (a) 표적의 산란점(향상된 OMP, $L=6$) (b) 표적의 산란점(향상된 OMP, $L=4$) (c) 표적의 산란점 (향상된 OMP, $L=3$).....	46
그림 4.2. 최적의 산란점 추출 기법.....	48
그림 4.3. 최적의 산란점 결과 (a) 향상된 OMP+최적화(5세대 후) (b) 향상된 OMP+최적화.....	49
그림 4.4. (a) 수렴 곡선(임의의 초기해) (b) 수렴 곡선(향상된 OMP로 얻은 초기해).....	50

그림 4.5. (a) A-380 카드 모델 (b) 유로파이터 카드 모델 (c) F-15 카드 모델.....	51
그림 4.6. (a) A-380 HRRP (b) 유로파이터 HRRP (c) F-15 HRRP.....	53
그림 4.7. (a) A-380의 복원된 영상 (b) 유로파이터의 복원된 영상 (c) F-15의 복원된 영상.....	54
그림 4.8. 추출된 산란점(향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	55
그림 4.9. 추출된 산란점(향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	56
그림 4.10. 초평면에 의한 분류.....	59
그림 4.11. 초평면 선택.....	60
그림 4.12. 비선형 SVM.....	62
그림 4.13. 식별 표적 (a) 표적 1(제트 스키) (b) 표적 2(선박) (c) 표적 3(잠망경)	64
그림 4.14. 표적 DB (a) 표적 1 (b) 표적 2 (c) 표적 3.....	65
그림 4.15. SNR에 따른 식별 결과 (a) k-NN (b) Bayes (c) SVM.....	67
그림 4.16. PCA, LDA의 최적화	68
그림 4.17. 커널 함수 최적화.....	70
그림 4.18. 수렴 곡선	72
그림 4.19. 추출된 특징점(PCA)	73
그림 4.20. 추출된 특징점(PCA+LDA)	73
그림 4.21. 식별 결과(시뮬레이션).....	74
그림 4.22. 잡음에 따른 식별 성공률	75
그림 4.23. 레이더 측정 시스템.....	77
그림 4.24. 로테이터.....	77
그림 4.25. 측정 표적 (a) A-380 (b) Eurofighter (c) F-15.....	78
그림 4.26. 측정 표적의 HRRP (a) A-380 (b) Eurofighter (c) F-15	79
그림 4.27. A-380 (a) 실제 표적 (b) SAR 영상	81
그림 4.28. Eurofighter (a) 실제 표적 (b) SAR 영상.....	82
그림 4.29. F-15 (a) 실제 표적 (b) SAR 영상.....	83
그림 4.30. 추출된 산란점(향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	84
그림 4.31. 추출된 산란점(향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15.....	85
그림 4.32. 수렴 곡선(12개의 관측 방위각).....	86
그림 4.33. 추출된 특징점(PCA, 12개의 관측 방위각)	87
그림 4.34. 추출된 특징점(PCA+LDA, 12개의 관측 방위각) ...	87

그림 4.35. 식별 결과(실험, 12개의 관측 방위각)	88
그림 4.36. 추출된 특징점(PCA, 6개의 관측 방위각)	89
그림 4.37. 추출된 특징점(PCA+LDA, 6개의 관측 방위각)	89
그림 4.38. 식별 결과(실험, 6개의 관측 방위각)	90
그림 4.39. 추출된 특징점(PCA, 3개의 관측 방위각)	91
그림 4.40. 추출된 특징점(PCA+LDA, 3개의 관측 방위각)	91
그림 4.41. 식별 결과(실험, 3개의 관측 방위각)	92
그림 4.42. 잡음에 따른 식별 성공률(SVM 최적화 전)	93
그림 4.43. 잡음에 따른 식별 성공률(SVM 최적화 후)	94

표 목차

표 2.1. 첩 신호의 파라미터	13
표 2.2. 산란점 위치와 반사계수	13
표 3.1. 산란점 위치와 반사계수	24
표 3.2. 시험 함수	37
표 3.3. 최적화 파라미터	39
표 3.4. 시험 함수들의 최적화 결과	40
표 4.1. 시뮬레이션 환경	52
표 4.2. 커널 함수	63
표 4.3. 유전 알고리즘의 파라미터	72
표 4.4. 실험 환경	76

기호 및 약어 설명

t	시간
f_0	초기 주파수
α	Chirp rate
(x, y)	관측 위치
(x_n, y_n)	n번째 산란점 위치
R_n	관측 위치와 n번째 산란점의 거리
t_n	관측 위치와 n번째 산란점까지의 수신 시간
σ_n	n번째 산란점의 반사 계수
Φ	샘플링 매트릭스
Ψ	Representation 매트릭스 혹은 Sparse basis
A	Transformation 매트릭스
r	잔차(Residual)
λ	서포트 벡터
θ	고각
φ	방위각
$\Phi(\cdot)$	비선형 매핑 함수
$K(\cdot)$	커널 함수
BMO	Bird Mating Optimizer
BPA	후광 영사 알고리즘 (Back Projection Algorithm)
CS	압축센싱 (Compressive Sensing)
DB	데이터 베이스 (Data Base)
FBP	Filtered Back Projection
IDFT	Inverse Discrete Fourier Transform
GA	유전 알고리즘
HRRP	고해상도 거리 프로파일 (High Resolution Range Profile)
LDA	Linear discriminant Analysis
LSM	최소자승법 (Least Squares Method)
OMP	Orthogonal Matching Pursuit
PCA	Principal Component Analysis
PO	물리광학법 (Physical Optics)
Radar	레이더 (Radio detection and ranging)
RCS	레이더 반사 면적 (Radar Cross Section)
SAR	합성 개구 레이더 (Synthetic Aperture Radar)
SL	Sparsity Level
SVM	서포터 벡터 머신 (Support Vector Machine)
VNA	Vector Network Analyzer
WOA	Whale Optimization Algorithm

제 1 장 서 론

1.1 연구의 배경

레이더(Radar : Radio Detection and Ranging) 표적 식별에 대한 연구는 그림 1.1과 같이 레이더에서 송신된 전자기파가 표적에 반사되어 수신되는, 표적의 특성을 지니고 있는 신호를 이용하여 해당 표적의 종류를 구분하는 연구이다. 광학, 적외선, 초음파 센서와 달리 레이더는 다른 센서들에 비해 장거리 표적을 식별할 수 있으며, 기상 상황에 크게 영향을 받지 않는다는 장점을 가지고 있다. 레이더는 이런 장점으로 인하여 국내의 주요 군사 시설을 타격하려는 적대국의 미사일이나 폭격기를 감지하는 국방 분야나, 보행자나 차량의 식별을 통한 자율주행 분야, 또는 항공 교통 관제 시스템에 주로 사용된다.

최근 국방 분야에서 사용되는 레이더의 경우, 전투기의 표면 구조에 맞게 탑재되는 능동 위상 배열 안테나(AESA : Active Electronically Scanned Array)를 이용한 공대공 탐지에 대한 관심이 증가하고 있다[1]. 적대국의 전투기의 종류를 식별하여 해당 기종에 대한 최적의 대응을 수행하여 교전에서의 우위를 점할 수 있다. 이는 정확한 표적 식별이 바탕이 되어야 하며, 표적 식별의 정확도는 레이더로부터 수신되는 표적 정보량에 비례한다. 그러므로 고해상도의 정보를 획득할 수 있는 레이더나, 더 많은 관측 각에서의 표적 신호 수신이 필요하다.




그림 1.1. 레이더 수신 신호

Fig 1.1. Received Radar signal

레이더에 사용되는 주파수 대역에 따라 얻어지는 표적 수신 신호가 달라지는데, L-밴드(1~2 GHz)나 S-밴드(2~4 GHz) 레이더의 경우 같은 전력으로도 더 먼 거리를 탐지할 수 있으나, X-밴드(8~12 GHz) 레이더는 보다 정확한 표적 정보를 획득할 수 있다. 그러므로 X-밴드의 레이더의 사용이 표적 식별의 정확도를 향상시키는데 유리하다. 최근에는 고출력, 고온 안정성, 고전력 밀도를 가지는 질화갈륨(GaN : Gallium Nitride) 전자소자를 이용한 전력증폭기의 발달로, 고출력의 X-밴드 레이더를 탑재한 전투기의 개발이 이루어지고 있다[2]. 이러한 고출력의 X-밴드 레이더를 탑재한 전투기로 표적 식별을 수행할 경우, 보다 정확한 표적 식별이 가능하다. 그리고 공대공 탐지 상황에서는 표적의 일부 관측 각 정보만 얻을 수 있다. 본 논문에서는 X-밴드의 레이더 시스템에서의 표적 식별을 수행하였으며, 제한된 관측 각에서 얻어진 수신 신호로 보다 정확한 표적 식별을 수행하는 기법에 대한 연구를 진행하였다.

표적 식별의 단계는 그림 1.2와 같이 표적 신호 수신, 특징점 추출, 표적 식별, 판별의 단계로 이루어지는데, 그 중 특징점 추출의 단계가 표적 식별 성능에 큰 영향을 미친다. 그러므로 표적의 어떤 특성을 나타내는 레이더 수신 신호를 사용할 것인지에 대한 연구가 필요하다. 본 논문에서는 표적 특성 신호로 산란점 정보를 이용한 표적 식별에 대한 연구를 진행하였다.




그림 1.2. 표적 식별 단계

Fig 1.2. Process of target identification

표적 식별의 단계에서는 기존에 획득한 표적 데이터베이스(DB : Data

Base)와의 유사성을 비교하여 표적의 종류를 판별하게 된다. 그러므로 축적된 데이터가 필요하게 되는데, 식별의 성공률을 높이려면 표적에 대한 다양한 데이터가 필요하다. 그림 1.3과 같이 RCS 데이터를 획득하여 데이터베이스를 구축하는 경우, 표적의 고각(θ), 방위각(φ), 주파수(f) 별로 RCS를 측정하여 데이터베이스를 구축하여 표적 식별의 성공률을 높일 수 있다. 본 논문에서는 표적의 데이터베이스를 구축하고 학습과 검증 데이터로 나누어 표적 식별을 수행하였다.




그림 1.3. 고각, 방위각, 주파수 별로 획득한 RCS 데이터베이스

Fig 1.3. RCS database acquired by elevation, azimuth, and frequency

표적 식별에 사용되는 표적 특성으로 레이더 반사 면적(RCS : Radar Cross Section), 고 해상도 거리 프로파일(HRRP : High Resolution Range Profile), 도플러(Doppler)와 같은 1차원 데이터와 합성 개구 레이더(SAR : Synthetic Aperture Radar)로부터 얻어지는 2차원 이미지가 있다[3-11]. [3]에서는 송신과 수신 위치가 다른 바이스테틱 RCS를 이용하여 전투기 표적의 식별을 수행하였으며, [5]에서는 주파수 별 스위핑하여 얻어진 광대역 RCS 이용하여 선박 표적의 식별을 수행하였다. [7]에서는 해상의 선박 표적으로부터 얻어지는 HRRP를

이용하여 표적 식별을 수행하였으며, [8], [9]에서는 HRRP를 이용하여 차량 표적의 식별을 수행하였다. [10]에서는 마이크로 도플러를 이용하여 점 산란 모델에 대한 표적 식별을 수행하였다. 위와 같은 1차원 데이터를 이용한 표적 식별의 경우에는 빠른 수신 신호의 획득 및 식별 수행이 가능하지만 관측 각에 따라 제한된 수신 신호만 획득할 수 있기에 식별 성능이 떨어진다는 단점이 있다. 그와 다르게 [11]과 같이 2차원 SAR 영상을 이용하여 산란점 모델을 생성한 후 표적 식별을 수행하는 경우, 필요한 데이터가 많아져 신호 획득과 식별 수행이 느려지지만, 보다 정확한 식별이 가능하다는 장점을 가지고 있다. 그러므로 정확한 표적 식별이 가능하며, 측정 및 연산 시간을 최소화시킬 수 있는 표적 특성을 선택하는 것에 대한 연구가 필요하다.

최근 레이더 표적 식별에서 산란점 정보를 사용하는 연구가 많이 이루어지고 있다[12–16]. 산란점은 레이더 수신 신호가 세계 나타나는 표적의 특정 부분으로 수신되는 신호의 크기와 위치 정보를 담고 있다. 이러한 산란점을 이용하면 높은 성능의 식별이 가능하다. 산란점을 추출하는 여러 기법들이 제시되어 있는데, 그 중 하나가 [12], [13]과 같이 압축 센싱을 이용하여 산란점을 추출하는 기법으로 측정 시간을 줄일 수 있다. 압축 센싱은 그림 1.4와 같이 측정과 샘플링을 하나의 과정으로 수행하여 측정 데이터의 수를 줄이는 기법이다[17].

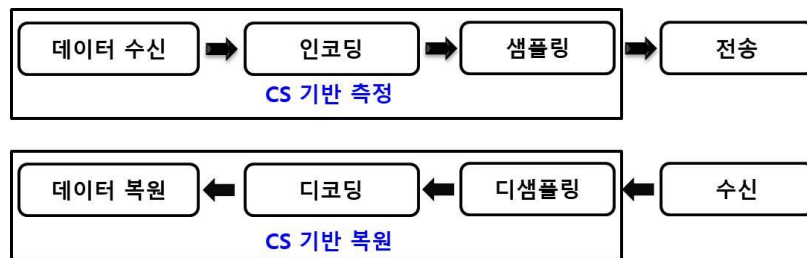


그림 1.4. 압축 센싱의 개념도

Fig 1.4. Concept of compressive sensing

압축 센싱을 이용하면 충분한 관측 각이 확보되지 않는 상황에서도,

많은 관측 각의 데이터로 얻어진 산란점과 유사한 정보를 추출할 수 있다. 압축 센싱 알고리즘의 하나인 orthogonal matching pursuit (OMP) 알고리즘의 경우 l_1 -norm 문제를 푸는 탐욕(Greedy) 알고리즘의 하나로 반복의 과정을 통해 문제를 해결한다[18]. 이러한 OMP 알고리즘은 필요로 하는 데이터가 적어 측정 시간을 줄일 수 있지만, 추출하려는 산란점의 수가 많을 경우 연산 시간이 증가하게 된다. 본 논문에서는 이러한 연산 시간의 증가를 억제할 수 있는 향상된 OMP 알고리즘을 제시하였다.

CS를 이용한 산란점 추출 기법의 경우, 적은 데이터로 원본 데이터와 유사한 산란점 정보를 얻을 수 있으나, 표적의 관측 각이 매우 적은 경우, 정확한 산란점 정보를 얻는데 어려움이 있다. 보다 정확한 산란점을 추출하는 기법에 대한 연구 중 하나로 최적화 알고리즘을 이용한 기법이 존재한다[19–21]. 역 산란(Inverse scattering) 문제를 최적화로 해결하는 기법으로 적은 데이터로도 정확한 산란점의 정보를 추정할 수 있으나, 연산 시간의 증가한다. 이에 정확한 전역 해(Global solution)를 찾으면서도 수렴성이 높은 새로운 최적화 알고리즘에 대한 연구가 필요하다. 본 논문에서는 표적의 산란점 정보를 설계변수로 하여 최적화를 수행하며, 설계변수가 많은 고차원 최적화 문제를 잘 푸는 최적화 알고리즘을 제안하였다. [22], [23]에 나타난 것과 같이 고차원 문제를 해결하는데 나선형 탐색이 유리하므로, 제안한 혼합 유전 알고리즘의 교차(Crossover) 방식으로 나선형 탐색(Spiral search)을 선택하였다. 그리고 수렴 속도가 빠른 결정론적 알고리즘의 특성과 전역 해 탐색에 유리한 확률론적 알고리즘의 특성을 모두 가질 수 있도록 해 집단을 여러 그룹으로 나누어 각 그룹마다 다른 방식의 교차 연산을 수행하여 해의 다양성을 보존하고 수렴성을 높였다[24, 25].

다음으로 앞서 제안한 향상된 OMP 알고리즘과 고차원 혼합 유전 알고리즘의 장점을 결합한 최적의 산란점 추출 기법에 대한 연구를 진행하였다. 향상된 OMP 알고리즘을 이용한 산란점 추출 기법의 경우 측정 데이터를 줄일 수 있으나, 제한된 관측 각으로 인한 산란점

정보의 부정확성이 발생한다. 혼합 유전 알고리즘을 이용한 산란점 추출 기법은 정확한 산란점 정보를 추출할 수 있으나 연산 시간이 증가한다. 이런 두 알고리즘의 장점을 취한 최적의 산란점 추출 기법을 제안하였다. 먼저 향상된 OMP 알고리즘을 이용하여 산란점 정보를 추출한 후, 획득한 산란점 정보를 초기값으로 두고 고차원 혼합 유전 알고리즘을 이용한 최적화를 수행하였다. 그 결과 정확한 산란점 정보를 획득하면서도, 연산 시간의 증가를 억제시킬 수 있었다. 최적의 산란점 추출 기법의 검증을 위해 시뮬레이션으로 얻어진 레이더 수신 신호에 적용하였다. 3 종류의 비행체 표적들을 대상으로 수치 해석적으로 얻어진 시뮬레이션 데이터에 최적의 산란점 추출 기법을 수행하여 제안한 산란점 추출 기법의 우수성을 확인하였다.

추출된 산란점 정보를 이용하여 표적 식별을 수행하였는데, 표적 식별에 사용되는 식별기의 종류에 따라 식별 성능이 달라지게 된다. 주로 사용되는 식별기로 k -NN, Bayes, 서포트 벡터 머신(SVM : Support Vector Machine)이 있다. [26]은 k -NN 식별기를 이용하여 지표면에 묻힌 지뢰 탐지 및 식별을 수행한 논문으로, k -NN은 구현이 간단하지만 저차원 데이터의 식별에 적합하며 DB 구조에 영향을 크게 받기에 본 논문에서 사용하기에는 적합하지 않다. Bayes 식별기는 적은 양의 DB로도 잘 동작하지만, 데이터의 분포에 따른 성능 변동이 있으며, 데이터가 가우시안 분포를 갖지 않는 경우 식별 성능이 저하되는 문제가 있다[27]. SVM은 커널 함수를 이용하여 비선형 분류가 가능하며, 고차원 데이터를 식별하는데 적합한 반면, 학습 속도가 떨어진다는 문제가 있다[28]. 본 논문에서는 고차원 식별에 적합하고 커널 및 커널 파라미터 최적화를 이용한 식별 성능 향상이 가능한 SVM 식별기를 선택하여 표적 식별을 수행하였다. 최적화를 통해 다른 식별기에 비해 더 좋은 식별 성능을 가지는 것을 확인하였다.

본 논문에서 제안한 최적의 산란점 추출 기법과 최적화된 SVM 식별기를 이용하여 실제 측정 데이터에 적용하였다. 그 결과 적은 측정 데이터로도 높은 식별 성공률을 보임을 확인할 수 있었으며, 연산

증가도 억제할 수 있음을 볼 수 있었다. 공대공 표적 식별에서는 식별 수행에서 획득할 수 있는 표적의 관측각은 제한적이며, 획득한 산란점 정보의 정확성도 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 알고리즘을 적용하면 보다 정확한 표적 식별을 수행할 수 있다.

1.2 논문의 구성

본 논문은 총 5장으로 구성되어 있으며, 각 장의 연구 내용은 다음과 같다.

제 1장에서는 연구 배경, 논문 구성에 대하여 서술하였다.

제 2장에서는 레이더 수신 신호로 사용된 칩 신호를 모델링하였으며, 시뮬레이션을 통하여 레이더 수신 신호가 표적의 정보를 제대로 반영하는지 검증하였다.

제 3장에서는 산란점 추출 알고리즘에 대한 연구를 진행하였다. 먼저 압축 센싱 기반의 산란점 추출 알고리즘에 대한 연구를 제시하였는데, 압축 센싱의 개념 설명과 기존의 압축 센싱 알고리즘의 구성을 설명하였으며 다음으로 본 논문에서 제안하는 향상된 압축 센싱 알고리즘을 설명하였다. 그리고 향상된 압축 센싱 알고리즘을 간단한 시간-주파수 영역 변환 문제에 적용하여 검증하였으며, 본 논문에서 적용할 산란점 추출 문제에도 검증을 진행하였다.

최적화 알고리즘 기반의 산란점 추출 연구에서는 본 논문에서 제안하는 고차원 혼합 유전 알고리즘의 개념에 대하여 설명하였으며, 여러 최적화 시험 함수에 대한 결과를 비교하여 최적화 알고리즘의 성능을 검증하였다. 또한 산란점 추출 문제에도 적용하여 검증하였다.

제 4장에서는 최적의 산란점 추출 및 기법에 대한 연구를 진행하였다. 먼저 앞서 제안한 향상된 CS 알고리즘과 고차원 혼합 유전 알고리즘을 결합한 최적의 산란점 추출 기법을 제안하였으며, 시뮬레이션 데이터를 이용하여 검증하였다. 다음으로 식별 알고리즘에서 사용되는 여러 식별기에 대한 비교를 수행하고 본 논문에 적합한 SVM을 선택하였다. 최적화가 가능한 SVM 식별기의 최적화 과정에 대하여 설명하였고,

앞서 추출한 산란점 정보에 최적화된 SVM을 이용한 표적 식별을 수행하였다. 시뮬레이션 데이터와 실제 측정 데이터에 모두 적용하였으며, 향상된 식별 성능을 보임을 확인하였다.

제 5장에서는 본 논문의 결과를 정리하고 향후 연구에 대하여 논의하였다.

제 2 장 레이더 수신 신호 모델링

본 장에서는 산란점 추출 알고리즘을 설명하기에 앞서 본 논문에서 사용되는 레이더 신호에 대한 설명과 표적에 반사되어 수신되는 신호의 모델링을 진행하려 한다. 그리고 시뮬레이션 결과를 통해 수신 신호에 대한 검증을 진행할 것이다.

2.1 수신 신호 모델링

레이더 수신 신호는 송신 레이더의 신호 특성에 따라 다르게 수신되는데, 본 논문에서는 시간에 따라 주파수가 증가하거나 감소하는 첵 (Chirp) 신호를 레이더 송신 신호로 사용하였다. 시간에 따라 주파수가 증가하는 첵 신호는 그림 2.1과 같은 형태를 가지게 된다. 그러므로 첵 신호를 통해 얻어지는 수신 신호는 표적의 여러 주파수에 대한 특성을 한번에 얻을 수 있다.




그림 2.1. 첵 신호

Fig 2.1. Chirp signal

칩 신호 s_t 은 수식 (2.1)과 같이 표현되는데, t 는 시간을, f_0 는 초기 주파수를, α 는 시간에 따른 주파수 증가율을 나타내는 chirp rate이다[29].

$$s_t(t) = e^{(j2\pi f_0 t + j\pi \alpha t^2)} \quad (2.1)$$

칩 신호 s_t 가 표적에 반사되어 수신되는 수신 신호 s_r 는 수식 (2.2)와 같이 표현된다. (x, y) 는 관측 위치를, (x_n, y_n) 은 n 번째 산란점의 위치를 나타내며, 관측 위치와 n 번째 산란점과의 거리를 r_n , n 번째 산란점에 반사되어 관측 위치로 수신되기까지의 시간을 t_n 으로 표기하였다. s_n 은 함께 수신되는 잡음을 나타낸 것이며 σ_n 은 n 번째 산란점의 반사계수를 의미한다.

$$s_r(x, y, t) = \sum_n \sigma_n \cdot e^{(j2\pi f_0(t-t_n) + j\pi \alpha(t-t_n)^2)} + s_n \quad (2.2)$$

$$t_n = \frac{2R_n}{c}, R_n = \sqrt{(x - x_n)^2 + (y - y_n)^2}$$

수신된 신호 s_r 은 디칩(Dechirp) 과정을 거쳐 표적과 관측 위치와의 거리 정보만을 남겨둘 수 있는데, dechirp의 과정은 수식 (2.3)에 나타나 있다[30]. $(\cdot)^*$ 는 complex conjugate를 나타낸다.

$$s_d(x, y, t) = s_r^*(x, y, t) \cdot s_t(t)$$

$$= \sum_n \sigma_n \cdot e^{(j2\pi f_0 t_n + j\pi \alpha t_n^2)} \cdot e^{(j2\pi \alpha t_n t)} + s_n \quad (2.3)$$

수식 (2.3)의 $e^{(j2\pi \alpha t_n t)}$ 텀(Term)만이 시간에 따라 변하므로, 수식 (2.4)와 같이 역 푸리에 변환(Fourier transform)을 통해 산란점의 정보를 확인할 수 있다. IDFT[\cdot]은 inverse discrete Fourier transform을 나타낸다[31].

$$IDFT[r(x, y, t)] \quad (2.4)$$

위의 과정을 거쳐 표적 수신 신호의 거리 프로파일 정보를 획득할 수 있다. 레이더의 거리 분해능은 주파수의 대역폭에 반비례하므로, 주파수 스위핑을 이용하면 주파수 대역폭이 넓어진 효과를 얻을 수 있다. 그러므로 얻어진 거리 프로파일 정보는 거리 분해능이 더 향상된 고 해상도 거리 프로파일 정보이다[32]. 본 논문에서는 고 해상도 거리 프로파일 정보로부터 산란점 정보를 추출해 내고 표적 식별에 사용할 것이다. 모델링된 레이더 수신 신호의 검증을 다음 절에서 진행할 것이다.

2.2 시뮬레이션 결과

앞서 모델링한 수신 신호로 거리 프로파일 정보를 제대로 획득할 수 있는지 확인하기 위하여 시뮬레이션 데이터를 이용하여 검증하였다. 송신 신호로 사용된 첩 신호의 파라미터는 표 2.1과 같다.

표 2.1. 첩 신호의 파라미터

Table 2.1. Parameter of chirp signal

f_0 (GHz)	8
Bandwidth (GHz)	4
샘플링 수	801
주파수 스위프 시간 (s)	10^{-8}
Chirp rate (Hz/s)	4×10^{17}

첩 신호가 반사되는 표적은 3개의 산란점을 가진 표적으로 두었으며 산란점들의 위치와 반사계수는 표 2.2와 같다.

표 2.2. 산란점 위치와 반사계수

Table 2.2. Location and reflectivity of scattering center

	Position (m,m)	Reflectivity
산란점1	(-0.2, 0.05)	0.5
산란점2	(0, -0.1)	0.8
산란점3	(0.1, 0.25)	0.25

표적의 위치를 그래프로 나타내면 그림 2.2과 같으며, 관측 위치는 원점인 (0,0)이다.




그림 2.2 산란점의 위치

Fig 2.2 Location of scattering center

위의 시뮬레이션 조건에서 획득한 수신 신호를 2.1절에서 설명한 dechirp 과정과 IDFT를 통해 표적의 거리 프로파일을 획득하면 아래의 그림 2.4와 같다. 표 2.2의 정보와 비교해보면 실제 산란점들의 위치에서 반사계수에 비례하는 만큼의 피크(Peak)가 생성됨을 볼 수 있다. 본 논문에서는 첩 신호를 이용하여 산란점 추출을 진행할 것이다.




그림 2.3 거리 프로파일

Fig 2.3 Range profile

제 3 장 최적의 산란점 추출 알고리즘

본 장에서는 산란점 추출 알고리즘에 대한 상세 설명과 검증을 진행할 것이다. 먼저 앞서 서론에서 언급한 것과 같이 산란점 추출 알고리즘에 대한 연구를 크게 2 부분으로 나누어 진행할 것이다. 압축 센싱 기반의 산란점 추출 알고리즘 부분과 최적화 알고리즘 기반의 산란점 추출 알고리즘으로 나누어 설명을 진행할 것이며, 기존의 알고리즘과 본 논문에서 제안하는 알고리즘에 대해 설명한 후, 시뮬레이션 결과를 이용한 검증을 진행할 것이다.

3.1 Compressive sensing 기반의 산란점 추출 알고리즘

압축 센싱 기법은 의학, 소나 영상 등 다양한 분야에서 적용되고 있는 신호처리 기법으로 최근에는 레이더 신호 처리에서도 많이 응용되고 있다[33–35]. 먼저 기존의 압축 센싱 기법에 대해 서술한 후, 본 논문에서 제안하는 향상된 압축 센싱 기법에 대한 자세한 설명을 진행할 것이다.

3.1.1 Compressive sensing

압축 센싱 기법은 진보된 신호처리 기법의 하나로 적은 일부의 측정 데이터로부터 전체 데이터를 복원하는 목적으로 연구되었다[36]. 압축 센싱 기법은 측정과 샘플링 과정을 한 번에 수행하여 측정 시간을 줄이고, 필요한 데이터도 줄일 수 있다. 그럼에도 불구하고 압축 센싱 기법을 이용한 복원은 CS 알고리즘의 추가로 기존의 복원 기법에 비해 연산량이 증가한다는 단점이 있다. 그러므로 전체 복원 시간을 줄이기 위해서는 연산 시간을 줄이는 방법에 대한 연구가 필요하다. 본 논문에서 제시하는 변형된 CS 알고리즘은 이러한 단점을 보완하는

방향으로 연구를 진행한 결과이다.

압축 센싱 기법을 적용하기 위해서는 다음과 같은 두 조건을 만족해야 한다[17]. 첫 번째로 신호가 성김(Sparsity)을 만족해야 한다. 성김을 만족하기 위해서는 신호에서 유의미한 값을 가진 요소가 적어야 한다. 또한 측정 영역(Domain)이 아닌 다른 영역에서 압축되어 보이는 성긴 신호(Sparse signal)로 보여야 한다. 예를 들면, 시간 영역에서 많은 정보를 가진 것처럼 보이는 신호를 FFT를 통해 주파수 영역에서 보면 일부의 주파수 성분만 가지는 압축된 신호로 변환시켜 볼 수 있는 경우가 있다. 이러한 조건에서 시간 영역을 측정 영역으로 하여 압축 센싱 기법을 적용할 수 있다.

측정 영역에서 얻어진 신호를 \mathbf{x} , 성긴 영역(Sparse domain)에서 보여지는 신호를 \mathbf{s} 라 두고, Ψ 를 두 신호의 관계를 나타내는 sparse basis 또는 representation matrix라고 두고, Φ 를 sampling matrix라 하면 아래의 수식 (3.1)과 같은 관계가 성립한다. \mathbf{A} 는 sparse basis와 sampling matrix를 곱한 매트릭스로 transformation matrix로 표현한다.

$$\mathbf{x} = \Phi\Psi\mathbf{s} = \mathbf{A}\mathbf{s} \quad (3.1)$$

압축 센싱은 수식 (3.1)을 만족하면서도 가장 성긴 신호를 찾는 기법으로 아래의 수식 (3.2)와 같이 표현된다. $\|\mathbf{s}\|_0$ 은 l_0 -norm을 나타내는 것으로 0이 아닌 원소들의 수를 나타낸다.

$$\min_{\mathbf{s}} \|\mathbf{s}\|_0 \text{ subject to } \mathbf{x} = \mathbf{A}\mathbf{s} \quad (3.2)$$

두 번째로 만족해야 하는 조건은 신호의 비간섭성(Incoherence)이다. 비간섭성은 sampling matrix와 representation matrix의 비간섭성을 의미하는 것으로, 샘플링 과정에서 무작위 샘플링을 수행하여 비간섭성 조건을 만족시킬 수 있다.

레이더 신호 처리의 경우 표적으로부터 수신되는 측정 신호는 성긴 신호가 아니지만, 거리 프로파일, SAR 영상과 같이 변형된 신호의 경우 성긴 신호이므로 CS 알고리즘을 적용하기에 적합하다고 볼 수 있다.

CS 알고리즘은 크게 2 가지 종류로 나눌 수 있다. 첫 번째로 l_1 -norm 최소화 문제를 푸는 알고리즘이 있으며, 두 번째로 OMP, Compressed Sensing Matching Pursuit(CoSaMP), Bayesian Fast Relevance Vector Machine(RVM)과 같은 탐욕 알고리즘 기반이 있다[37–39]. 탐욕 알고리즘은 l_1 -norm 최소화를 푸는 알고리즘에 비해 더 빨리 해를 찾을 수 있으므로 본 논문에서는 탐욕 알고리즘 기반의 CS에 대한 연구를 진행하였다.

먼저 OMP 알고리즘에 대해 개략적으로 알아보려 한다. OMP 알고리즘은 Mallat에 의해 제안된 탐욕 알고리즘의 하나로 반복에 의해 수행된다. 매 반복 마다, 알고리즘은 0이 아닌 성분을 추정하고, 다음 반복에서 이전에 추정된 0이 아닌 성분을 원 신호에서 제거한 잔차(Residual) 신호로부터 다시 0이 아닌 성분을 추정한다. 이러한 방식으로 순차적으로 가장 큰 0이 아닌 성분을 추정해가는 것이 OMP 알고리즘이다. OMP 알고리즘의 순서도는 그림 3.1에 나타나있다.

먼저 초기화(Initialization) 후 OMP 알고리즘은 대리 신호(Signal Proxy) \mathbf{x}_s 를 계산한다. 대리 신호 \mathbf{x}_s 는 이전 반복의 잔차 \mathbf{r}_{i-1} 에 \mathbf{A}^T 를 곱하여 얻을 수 있는데, 이는 transformation matrix \mathbf{A} 를 orthogonal matrix로 보기 때문이다. 그러므로 수식 (3.3)과 같이 성긴 신호 \mathbf{s} 와 유사한 \mathbf{x}_s 를 추정할 수 있다.

$$\mathbf{x}_s = \mathbf{A}^T \mathbf{r}_0 = \mathbf{A}^T \mathbf{x} = \mathbf{A}^T (\mathbf{A} \mathbf{s}) \approx \mathbf{s} \quad (3.3)$$

다음 단계에서 OMP 알고리즘은 대리 신호 \mathbf{x}_s 를 이용하여 성긴 신호 \mathbf{s} 의 가장 큰 성분에 관련된, transformation matrix 내의 위치인 서포트(Support) λ_i 를 추정할 수 있다. Transformation matrix \mathbf{A} 에서

획득한 서포트 λ_i 의 성분들만을 추출하여 이전 세대의 \mathbf{A}_{i-1} 과의 합을 통해 \mathbf{A}_i 를 획득할 수 있다. 다음으로 최소자승법(LSM : Least Squares Method)을 이용하여 성긴 신호 $\hat{\mathbf{s}}_i$ 을 추정할 수 있다. 최소자승법은 목표로 하는 신호와의 오차의 제곱을 최소화하도록 하는 기법으로 inverse 문제를 해결하는데 유용하게 사용되는 기법이다[40]. 추정된 신호 $\hat{\mathbf{s}}_i$ 에 \mathbf{A}_i 를 곱하고 측정된 신호 \mathbf{x} 와의 차를 계산하면 i 번째 반복의 잔차 \mathbf{r}_i 를 구할 수 있다. 이와 같은 과정을 sparsity level (SL)에 도달할 때까지 반복하게 되는데, sparsity level은 성긴 신호에서 0이 아닌 원소의 수만큼 설정한다.

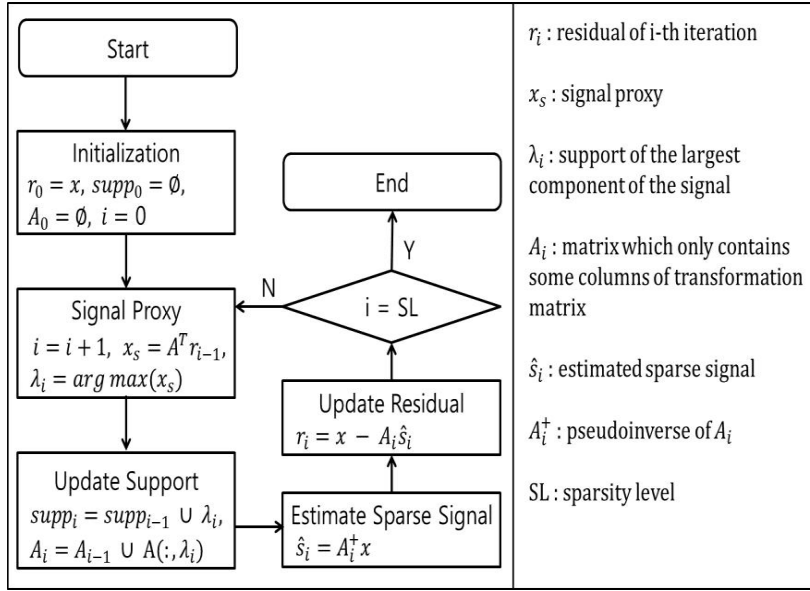


그림 3.1. OMP 알고리즘의 순서도

Fig 3.1. Flowchart of the OMP algorithm

3.1.2 향상된 CS 알고리즘

앞서 설명한 OMP 알고리즘의 경우, 어느 정도의 sparsity level을 알고 있어야 하며, 신호 \mathbf{s} 의 가장 큰 성분을 매 반복마다 하나씩 추정하게 된다. CoSaMP 알고리즘의 경우는 OMP에서 변형되어 신호 \mathbf{s} 의 큰 성분들을 매 반복마다 여러 개씩 추정하게 된다. 그러나 산란점

추출, 영상 복원과 같은 레이더 신호 처리에서는 표적으로부터 얻어지는 신호들이 최종적으로 마스킹(Masking) 처리되어 얻어지게 되므로, 특정한 임계값(Threshold) 이하의 값들은 버려지는 것이라 볼 수 있다. 그러므로 이러한 레이더 신호 처리의 특수성에서 기인한, 향상된 OMP 알고리즘을 제안하려 한다. 그림 3.2는 향상된 OMP 알고리즘의 순서도를 나타낸 것으로, 기존의 OMP와 다른 점은 다음과 같다.

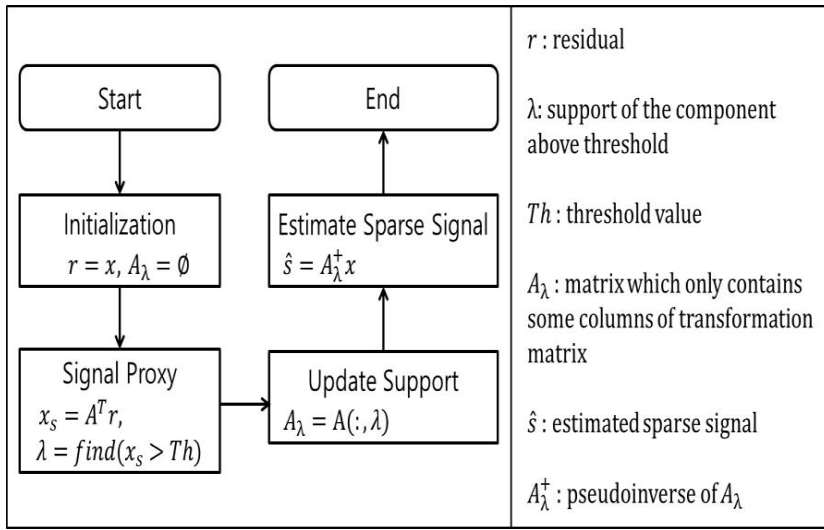


그림 3.2. 향상된 OMP 알고리즘의 순서도

Fig 3.2. Flowchart of the improved OMP algorithm

대리 신호 획득 단계에서 기존의 OMP와는 다르게 반복으로 가장 큰 값의 서포트를 획득하는 대신, 향상된 OMP 알고리즘은 임계값을 이용하여 특정 임계값 이상을 가지는 서포트들의 벡터인 λ 를 한꺼번에 획득한다. 그리고 transformation matrix에서 λ 에 해당하는 부분의 행렬을 뽑아 A_λ 를 획득한다. 다음으로 성긴 신호 \hat{s} 를 최소자승법을 이용하여 획득하게 되고, 이전의 OMP 알고리즘과 다르게 알고리즘이 종료된다. 이와 같이 반복을 제거하면 기존의 OMP 알고리즘에 비해 연산 속도를 크게 향상시킬 수 있다. 제안한 알고리즘의 검증을 위해 간단한 FFT 문제와 산란점 추출 문제에 적용하여 검증을 진행하였다.

3.1.3 시뮬레이션 결과

먼저 간단한 FFT 문제를 해결하는데 향상된 OMP 알고리즘을 적용해 보았다. 아래의 수식 (3.4)와 같이 서로 다른 5개의 주파수를 가진 신호를 표현한 것이다.

$$\mathbf{x} = \sum_{k=1}^5 \sin(2\pi f_k t) \quad (3.4)$$

$$\mathbf{f} = [130, 220, 300, 390, 440] \text{ Hz}$$

수식 (3.4)의 신호를 시간 영역에서 보면 그림 3.3과 같이 여러 주파수의 신호가 혼합되어 복잡한 신호를 가지는 것을 확인할 수 있다. 측정 영역인 시간 영역에서는 성진 신호가 아니지만, FFT를 통해 주파수 영역에서 보면 5개의 주파수를 지닌 신호이므로 5 개의 피크를 가진 성진 신호가 얻어질 것이다[41].




그림 3.3. 시간 영역에서의 신호 \mathbf{x}

Fig 3.3. Signal \mathbf{x} in time domain

이 신호에서 무작위로 10%의 신호만을 샘플링하면 그림 3.4와 같이 기존의 신호와 크게 달라진 신호를 획득할 수 있다. 이러한 신호의

경우 CS를 적용할 수 있는 2 가지 조건을 만족되었으므로, 향상된 OMP 알고리즘을 적용할 수 있다. Transformation matrix \mathbf{A} 는 IDFT matrix에 sampling matrix의 곱이 되며, 잡음을 고려하여 임계값을 0.1로 두고 향상된 OMP 알고리즘을 적용하면 그림 3.5와 같은 결과를 얻을 수 있다.




그림 3.4. 10%의 무작위 샘플링된 신호

Fig 3.4. 10% randomly sampled signal




그림 3.5. 향상된 OMP 알고리즘으로 획득한 성진 신호 \mathbf{s} 의 크기

Fig 3.5. The amplitude of resultant sparse signal \mathbf{s} with improved OMP algorithm

기존의 10%의 측정 데이터만으로 5개의 주파수 성분만을 가지는 성진 신호를 잘 복원하는 것을 확인할 수 있었으며, 기존의 OMP 알고리즘에 비해 약 43%의 연산 시간을 줄일 수 있었다. SL이 5이기에 43%의 절감이 발생하였으며, SL이 높을 경우 더 많은 연산 시간의 감소가 발생할 것으로 보인다.

다음으로 이상적인 점 표적으로 구성된 표적에서의 산란점 추출 문제에 향상된 OMP 알고리즘을 적용해 보았다. 표적을 두고 원형으로 돌아가며 관측을 수행하여 측정 데이터를 획득한다고 가정하였다. 관측 각의 경우 고각 θ 는 90도로 고정한 후, 방위각 φ 만 조절하며 데이터를 획득하였다.

수신된 신호 \mathbf{x}_m 는 수식 (2.3)에 나타난 수신 신호 모델링에서 얻어진 FFT 변환되기 전의 디칩된 신호로 두었다. K 는 샘플링 수, L 은 측정 방위각의 수, N 은 산란점의 수, (x_n, y_n) 는 표적의 n 번째 산란점 위치, p_n 은 n 번째 산란점의 반사 계수, R 은 표적과 관측점 사이의 거리, $r_{l,n}$ 은 l 번째 관측점과 n 번째 산란점과의 거리, φ_l 는 l 번째 방위각을 의미한다. 잡음 n_{wg} 는 수신된 신호의 파워를 기준으로 추가된 화이트 가우시안 잡음으로 두었다.

$$\begin{aligned} \mathbf{x}_m(\varphi_l, t_k) &= \sum_{n=1}^N p_n \cdot e^{\left\{j4\pi f_0 \frac{r_{l,n}}{c} + j\pi\alpha \left(\frac{2r_{l,n}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi\alpha \left(\frac{r_{l,n}}{c}\right)t_k\right\}} \\ &\quad + n_{wg}, [L \times K] \end{aligned} \quad (3.5)$$

$$r_{l,n} = \sqrt{(R\cos\varphi_l - x_n)^2 + (R\sin\varphi_l - y_n)^2}$$

CS를 적용하기 위해서는 수신 신호를 벡터로 표현해야 하므로, 수식 (3.6)과 같이 수신 신호 \mathbf{x}_m 를 1열 벡터로 나타낸다.

$$\begin{aligned} \mathbf{x} &= [x_m(\varphi_1, t_1), x_m(\varphi_1, t_2), \dots, x_m(\varphi_1, t_K), \dots, \\ &\quad x_m(\varphi_L, t_1), x_m(\varphi_L, t_2), \dots, x_m(\varphi_L, t_K)]^T, [K \cdot L \times 1] \end{aligned} \quad (3.6)$$

1열 벡터인 표적 산란점의 반사 계수 \mathbf{p} 는 수식 (3.7)과 같다.

$$\mathbf{p} = [p_1, p_2, \dots, p_n]^T, [N \times 1] \quad (3.7)$$

표적의 반사계수 \mathbf{p} 와 수신 신호 \mathbf{x} 의 관계를 나타내는 representation matrix $\mathbf{\Psi}$ 는 수식 (3.8)와 같다.

$$\mathbf{\Psi} = \begin{bmatrix} e^{\left\{j4\pi f_0 \frac{r_{1,1}}{c} + j\pi \alpha \left(\frac{2r_{1,1}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{1,1}}{c}\right)t_1\right\}}, \dots, e^{\left\{j4\pi f_0 \frac{r_{1,N}}{c} + j\pi \alpha \left(\frac{2r_{1,N}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{1,1}}{c}\right)t_1\right\}} \\ \vdots \\ e^{\left\{j4\pi f_0 \frac{r_{L,1}}{c} + j\pi \alpha \left(\frac{2r_{L,1}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{L,1}}{c}\right)t_K\right\}}, \dots, e^{\left\{j4\pi f_0 \frac{r_{L,N}}{c} + j\pi \alpha \left(\frac{2r_{L,N}}{c}\right)^2\right\}} \cdot e^{\left\{j4\pi \alpha \left(\frac{r_{L,N}}{c}\right)t_K\right\}} \end{bmatrix} \quad (3.8)$$

, $[K \cdot L \times N]$

수신 신호 \mathbf{x} 는 샘플링 매트릭스 $\mathbf{\Phi}$ 와 representation matrix $\mathbf{\Psi}$ 를 \mathbf{p} 에 곱하여 얻어진다. 표적이 있는 픽셀의 반사 계수 \mathbf{p} 는 성긴 신호이다. 그리고 얻어진 수신 신호는 \mathbf{x} 는 성긴 신호가 아니며, 무작위 샘플링을 수행하면, 아래의 수식 (3.9)와 같은 CS 문제가 된다.

$$\mathbf{x} = \mathbf{\Phi}\mathbf{\Psi}\mathbf{p} = \mathbf{A}\mathbf{p} \quad (3.9)$$

2.2절의 시뮬레이션 환경에서 사용된 첩 신호의 파라미터를 똑같이 사용하였으며, 표적과 관측 점과의 거리인 $R=4\text{m}$ 로, 관측 방위각의 수인 $L=12$ 개로 설정하였으며, 무작위로 선택된 관측 점에서 측정이 이루어졌다. 산란점과 관측 점 위치가 그림 3.6에 표시되어 있다.

좌표의 중심에 8개의 산란점을 가진 표적을 두었으며, 임의로 12개의 관측 방위각 $\varphi = [54 \ 86 \ 90 \ 104 \ 116 \ 158 \ 185 \ 188 \ 232 \ 241 \ 285 \ 360]^\circ$ 를 선택했다. 그리고 수신되는 신호에 10 dB 화이트 가우시안 잡음을 추가하였다. 표적의 산란점들의 위치와 반사 계수는 아래의 표 3.1과 같다.




그림 3.6. 산란점 위치와 관측점 위치


Fig 3.6. The position of scattering center and observation point

표 3.1. 산란점 위치와 반사계수


Table 3.1. Location and reflectivity of scattering center

	Position (m,m)	Reflectivity
산란점1	(0, -3)	1
산란점2	(-0.225, -0.1125)	0.85
산란점3	(0.225, -0.15)	0.7
산란점4	(0, 0)	0.9
산란점5	(-0.3375, 0.15)	0.75
산란점6	(0.3, 0.225)	0.95
산란점7	(-0.1125, 0.3375)	0.75
산란점8	(0.1125, 0.3375)	0.9

비교를 위해 기존의 OMP 알고리즘과 향상된 OMP 알고리즘을 모두 적용하여 산란점 추출을 진행하였다. 산란점 추출 결과는 아래의 그림 3.7에 나타나있다. 기존의 OMP 알고리즘에 비해 제안된 OMP 알고리즘은 81.2%의 연산 시간이 줄어들었으며, 유사한 성능을 보였다.



(a)




(b)


그림 3.7. (a) 추출된 산란점(향상된 OMP) (b) 추출된 산란점(OMP)

Fig 3.7. (a) Extracted scattering center(Improved OMP) (b) Extracted scattering center(OMP)

실제 산란점의 위치를 정확하게 추정하는 것을 확인할 수 있었으며, 산란점의 반사 계수 값들도 거의 일치하였다. 또한 CS가 아닌 다른 영상 복원 방법과의 비교를 위하여 후광 영상 알고리즘 (BPA : Back Projection Algorithm)에 의해 얻어진 영상과 비교해 보았다[42, 43].



(a)



(b)

그림 3.8. (a) 추출된 이미지(BPA, 12개의 임의의 관측 방위각) (b) 추출된 이미지(BPA, $\phi = 0 \sim 359^\circ$)

Fig 3.8. (a) Extracted image(BPA, 12 randomly selected observation azimuth angles) (b) Extracted image(BPA, $\phi = 0 \sim 359^\circ$)

BPA는 SAR 영상 복원 알고리즘의 하나로 시간 영역에서의 신호 처리를 통해 얻어진다. 임의의 12개의 관측 방위각을 사용한 CS와 동일한 방위각만을 사용한 BPA 영상과 1도 간격의 360개의 방위각을 모두 사용한 BPA 영상을 획득하였으며, 그 결과는 그림 3.8과 같았다. 그림 3.8(a)의 경우 CS와 동일한 12개의 방위각만을 사용한 결과로 어느 정도 산란점의 위치가 보이지만 열화가 발생하여 반사 계수의 값이 부정확하며, 산란점 주변의 일부 픽셀의 경우 상당히 높은 반사 계수가 나타나는 것을 볼 수 있다. 그러므로 CS가 적은 관측 각에서 얻은 데이터로 보다 정확한 산란점 정보를 얻을 수 있음을 알 수 있다.

그림 3.8(b)는 1도 간격으로 0~359도의 방위각에서 얻은 데이터를 모두 사용하여 영상을 복원한 결과이다. 결과를 확인해 보면 산란점의 위치는 잘 추정하는 것으로 보이나, 산란점의 반사 계수에 약간의 오차가 존재하며, 산란점 주변의 픽셀에서 반사 계수 값이 어느 정도 나타나는 것을 알 수 있다. 향상된 OMP로 얻어진 그림 3.7(a)과 비교해 보면, 향상된 OMP가 BPA보다 산란점 정보를 잘 추출하며 복원된 영상에 마스킹을 적용한 것과 같은 효과를 보여, 실제 표적 식별을 수행하는데 더 유용할 것으로 보인다. 연산 시간을 비교해 보면, 향상된 OMP를 사용하여 산란점을 추출하는 경우 약 0.4153초의 연산 시간이 걸렸으며, 임의의 12개의 방위각을 이용한 BPA의 경우 약 0.0616초가 걸렸고, 360개의 모든 방위각을 이용한 BPA의 경우 약 0.4492초가 걸렸다. 이로 보아 12개의 방위각을 사용한 BPA 보다 시간이 많이 걸리지만 산란점 추출 성능은 뛰어나며, 360개의 방위각을 사용한 BPA와 성능은 유사하지만, 연산 시간은 약 7.57% 적게 걸리는 것을 확인할 수 있다. 보다 적은 관측 각의 데이터를 사용할 경우 산란점의 정확도는 떨어지나 연산 시간은 더 감소할 것이다. 본 논문에서는 향상된 OMP를 적용하여 추출된 산란점 정보를 기반으로 표적 식별을 진행한다. 다음 절에서는 또 다른 산란점 추출 방법 중의 하나인 최적화 기반의 산란점 추출에 대한 연구를 진행할 것이다.

3.2 최적화 알고리즘 기반의 산란점 추출

최적화 알고리즘을 적용하여 표적의 산란점을 추출하는 연구가 많이 이루어지는데, 본 논문에서는 산란점 정보를 설계 변수로 두고, 수신된 신호와의 오차를 최소화하는 최적화를 수행하여 표적의 산란점 정보를 획득할 것이다. 표적의 크기와 형태에 따라 산란점의 위치와 수가 다른데, 복잡한 표적일수록 산란점의 수가 많아지는 경향을 보인다. 그러므로 많은 설계 변수를 가진 문제를 해결할 수 있는, 즉 고차원 최적화 문제를 풀 수 있는 최적화 알고리즘에 대한 필요가 발생한다.

최적화 알고리즘은 크게 결정론적(Deterministic) 알고리즘과 확률론적(Stochastic) 알고리즘으로 나누어져 있다. 결정론적 알고리즘은 conjugate gradient, steepest descent, gradient descent 알고리즘과 같이 지역 탐색(Local search)에 강하고 수렴 속도가 빠른 알고리즘이다[44-46]. 그러나 전역 탐색이 약하며, 그로 인해 최적해를 찾지 못할 확률이 높다는 단점이 존재한다. 확률론적 알고리즘은 전역 탐색 능력을 강화하기 위해 확률적인 요소를 추가한 알고리즘이다. Evolutionary strategy(ES), genetic algorithm(GA)와 같이 전역 탐색 능력이 강하며, 지역 해가 많은 문제에서도 최적해를 잘 찾는 알고리즘이다[47, 48]. 하지만 수렴 속도가 느리다는 단점이 있다. 이러한 두 알고리즘의 장점을 혼합하여 나온 것이 혼합 최적화 알고리즘이다. 혼합 최적화 알고리즘은 전역 탐색 능력도 강하며, 수렴 속도도 향상시킨 알고리즘으로, 이런 혼합 최적화 알고리즘에 대한 연구가 많이 이루어지고 있다. 본 장에서는 먼저 제시하려는 혼합 유전 알고리즘의 기반이 되는 최적화 알고리즘에 대해 간단하게 설명할 것이며, 고차원 문제를 해결하는데 강한 새로운 혼합 유전 알고리즘을 제안할 것이다. 그리고 여러 시험 함수들과 시뮬레이션 데이터를 이용한 산란점 추출 문제에 적용하여 검증을 진행할 예정이다.

3.2.1 혼합 유전 알고리즘

본 논문에서는 유전 알고리즘을 기반으로 결정론적 기법을 추가한 새로운 혼합 유전 알고리즘을 제시할 것이다. 앞서 언급한 것과 같이 표적의 산란점 수가 많을 수 있기에, 설계 변수가 많은 문제를 해결하는 최적화 알고리즘이 필요하다. 일반적인 유전 알고리즘의 경우 그림 3.9와 같은 순서로 진행된다. 초기해 생성 단계에서 GA의 인구수와 같은 임의의 n 개의 해를 생성하게 되며, 다음으로 선택, 교차, 변이의 단계를 거쳐 새로운 해인 자식 해를 생성하게 된다. 다음으로 생성된 자식 해를 기존의 부모 해 집단과 비교하여 대치를 수행하게 되며, 마지막으로 수렴 여부를 판별하여 다음 세대로 넘어갈 해를 결정하게 된다[48].

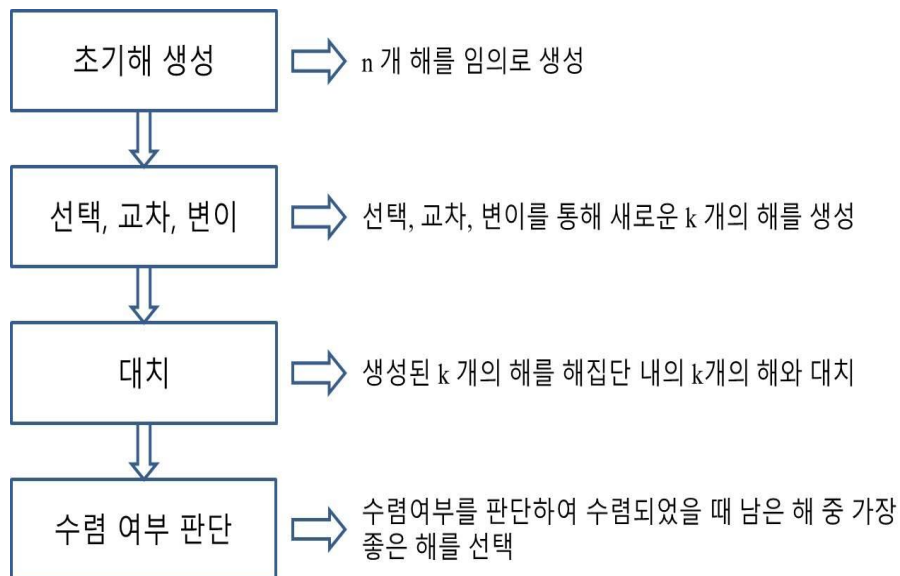


그림 3.9. 유전 알고리즘의 순서도

Fig 3.9. Flowchart of the GA

생성되는 자식 해의 경우, 앞서 어떤 선택, 교차, 변이 전략을 택하였는지에 따라 얻어지는 자식 해가 달라진다. 그 중 어떤 교차 전략을 선택하는지에 따라 생성되는 자식 해의 특성에 큰 영향을 주게

된다. 일점 교차, 다점 교차, 균등 교차, 산술적 교차 등 여러 가지 종류의 교차 전략이 존재하며, 본 논문에서는 whale optimization algorithm (WOA)에서 영감을 얻어 나선형 교차 전략을 택하였다.

WOA 알고리즘은 혹등고래가 먹이를 사냥하는 방법을 모사한 알고리즘으로, 나선형으로 돌며 먹이를 포위하는 행동에서 영감을 받아 나선형 탐색을 수행한다[22]. 이러한 나선형 탐색은 고차원 최적화 문제를 해결하는데 강점을 가진다. 본 논문에서는 나선형 탐색 방법을 자식 해를 생성하는 교차 전략으로 사용하였다.

혼합 유전 알고리즘을 생성하는 방식은 3 가지로 나눌 수 있다. 첫 번째는 결정론적 최적화 방법으로 얻어진 해를 GA의 초기 해로 사용하는 방법이다. 두 번째는 결정론적 최적화 방법의 탐색 전략을 GA의 교차 전략으로 사용하는 방법이다. 마지막은 GA로 얻어진 해들에 결정론적 최적화 방법을 적용하는 것이다[49]. 첫 번째 방법은 특정 문제를 푸는데 적합하지만, 일반적인 문제에 적용하는데 어려움이 있다. 두 번째 방법은 수렴을 향상시키지만 전역 해를 찾는 성능이 감소하게 된다. 마지막 방법은 기존의 GA를 수행하는 시간에 결정론적 최적화 수행 시간도 추가되므로, 연산 시간이 오래 걸린다는 단점이 있다.

이러한 문제점을 해결하면서 전역 해 탐색 능력을 높이기 위하여 bird mating optimizer (BMO) 알고리즘의 그룹을 나누어 서로 다른 교차 전략을 적용하는 기법을 참고하였다. BMO 알고리즘은 조류들의 종에 따라 다른 짝짓기 방식을 가지고 있다는 점에서 영감을 받아 만들어진 알고리즘이다[24]. 해 집단을 여러 그룹으로 나누어 서로 다른 교차 전략을 적용하여 해의 다양성을 높일 수 있다. 본 논문에서는 이러한 BMO의 교차 전략을 변형하여, 해 집단을 결정론적 최적화 방식으로 탐색하는 집단과, 지역 탐색에 강한 집단, 전역 탐색에 강한 집단, 무작위 탐색을 하는 집단으로 나누어 서로 다른 교차 전략을 수행하였다. 제안하는 혼합 유전 알고리즘에 대한 상세 설명은 아래에서 진행될 것이다.

본 논문에서 교차 전략으로 선택한 나선형 교차 전략은 아래의 수식 (3.10)과 같은 방식으로 자식 해를 생성하게 된다. \mathbf{X}_c 는 자식 해를 의미하며, $\mathbf{X}_1, \mathbf{X}_2$ 는 선택된 두 부모 해를 나타낸다. 그리고 r 는 $-1 \sim 1$ 사이의 임의의 값을 나타낸다.

$$\mathbf{X}_c = |\mathbf{X}_2 - \mathbf{X}_1| \cdot e^{r \cos(2\pi r)} + \mathbf{X}_1 \quad (3.10)$$

나선형 교차 전략에 의해 생성되는 자식 해들은 그림 3.10과 같은 형태로 \mathbf{X}_1 과 \mathbf{X}_2 의 사이를 회전하며 생성되게 된다.




그림 3.10. 나선형 교차

Fig 3.10. Spiral crossover

이와 같은 나선형 교차는 GA에서 주로 사용되는 산술적 교차에 비해 설계변수가 많은 문제를 잘 해결한다는 강점을 가지고 있다. 앞서 설명한 것과 같이 제안하는 교차원 혼합 유전 알고리즘에서는 여러 그룹으로 나누어 서로 다른 교차 전략을 적용하며, 나선형 교차 전략을 기본으로 변형된다.

제안하는 교차원 혼합 유전 알고리즘에서는 해 집단을 목적함수 (Objective function)의 값에 따라 4개의 그룹으로 나누었다. 가장

좋은 목적 함수 값을 가지는 해들은 최고 그룹(Best group)으로 두었으며, 이 그룹의 주변에 더 좋은 값을 가지는 해들이 있을 확률이 높으므로, 지역 탐색 능력이 뛰어난 gradient descent algorithm을 적용하였다. 다음으로 좋은 목적 함수 값을 가진 해들을 지역 그룹(Local group)으로 두었으며, 지역 탐색이 강하며, 확률론적인 요소도 추가된 교차 전략을 선택하였다. 그리고 세 번째로 좋은 목적 함수 값을 가진 해들을 전역 그룹(Global group)으로 두었으며, 전역 탐색 능력이 강하며, 해의 다양성을 유지할 수 있는 교차 전략을 선택하였다. 마지막으로 목적 함수 값이 가장 나쁜 해들은 무작위 그룹(Random group)으로 두고 임의의 부모 해를 생성하여 교차 전략을 수행하였다.

최고 그룹의 경우 앞서 설명한 것과 같이 gradient descent 알고리즘을 적용하여 자식 해를 찾았다. Gradient descent 알고리즘은 함수 값의 변화가 가장 큰 방향을 구하여 그 반대 방향으로 가면 극소점을 찾을 수 있다는 개념에서 나온 알고리즘으로 지역 탐색에 특화된 알고리즘이다[46].

나머지 그룹들은 기본적으로 자신의 그룹에서 하나의 부모 해를 선택하며 나머지 부모 해는 최고 그룹에서 선택하여 나선형 교차 전략을 적용한다. 이는 좋은 해 집단을 중심에 두고 나선형으로 돌아가며 해를 탐색하기 위함이다.

지역 그룹은 아래의 수식 (3.11)과 같은 방법으로 자식 해를 생성한다. 지역 그룹의 교차 전략을 통해 생성되는 자식 해 $\mathbf{X}_{c,local}$ 은 지역 그룹 내에서 선택된 부모 해 $\mathbf{X}_{p,local}$ 과 가장 가까운 최고 그룹의 해인 $\mathbf{X}_{p,best}$ 를 나머지 부모 해로 선택하여 자식 해를 생성한다. 이와 같은 교차 전략을 통해 근처 최고 그룹의 해 주변을 탐색하여 지역 탐색 능력을 향상시켰다.

$$\mathbf{X}_{c,local} = |\mathbf{X}_{p,best} - \mathbf{X}_{p,local}| \cdot e^r \cos(2\pi r) + \mathbf{X}_{p,best} \quad (3.11)$$

전역 그룹의 교차 전략은 수식 (3,12)과 같다. 전역 그룹의 교차 전략을 통해 생성되는 자식 해 $X_{c,global}$ 은 전역 그룹 내에서 선택된 부모 해 $X_{p,global}$ 과 최고 그룹의 해들 중에서 무작위로 선택된 $X_{r,p,best}$ 를 부모 해로 두고 자식 해를 생성한다. 전역 그룹의 해들은 해 집단 내에서 목적 함수 값이 나쁜 그룹이므로 좀 더 넓은 범위를 탐색할 필요가 있기에, 부모 해로 선택되는 최고 그룹의 해를 무작위 선정하였다.

$$X_{c,global} = |X_{r,p,best} - X_{p,global}| \cdot e^r \cos(2\pi r) + X_{r,p,best} \quad (3.12)$$

무작위 그룹은 아래의 수식 (3.13)와 같은 방법으로 자식 해를 생성한다. 무작위 그룹은 해의 다양성을 보존하기 위한 집단으로 생성되는 자식 해 $X_{c,random}$ 은 무작위로 생성된 부모 해 $X_{p,random}$ 과 최고 그룹에서도 가장 좋은 값을 가지는 최적 해(Best solution) X_{best} 를 나머지 부모 해로 선택하여 자식 해를 생성한다. 이와 같은 방법으로 자식 해를 생성함으로써 세대가 지날수록 줄어드는 해의 다양성을 어느 정도 보존해 줄 수 있다.

$$X_{c,random} = |X_{best} - X_{p,random}| \cdot e^r \cos(2\pi r) + X_{best} \quad (3.13)$$

제안한 혼합 유전 알고리즘의 자식 해 생성 방식이 그림 3.11에 정리되어 있다. 앞서 설명된 것과 같이 최고 그룹의 해는 근방의 더 나은 해를 탐색하며, 지역 그룹의 해는 주변에 가장 가까운 최고 그룹의 해의 주변을 나선형으로 돌아가며 탐색하게 된다. 전역 그룹의 해는 무작위로 선택되는 최고 그룹 해의 주변을 탐색하게 되므로, 가까운 최고 그룹의 해가 아닌, 좀 더 떨어진 최고 그룹의 해 주변을 탐색할 수 있다. 마지막으로 무작위 그룹은 무작위로 생성한 해를 최적 해의 주변을 탐색하도록 한다.




그림 3.11. 혼합 유전 알고리즘의 자식 해 생성 방법

Fig 3.11. Method of child solution generation in hybrid GA

그림 3.12는 제안한 혼합 유전 알고리즘의 순서도를 나타낸 것이다. 알고리즘의 단계는 다음과 같다.

Step 1) 초기화 : 먼저 초기화 단계에서 임의의 해 집단을 생성하게 된다. 생성되는 해들은 유전 알고리즘에서 설정된 인구 수만큼 생성되며 주어진 경계 조건 내에서 무작위로 생성하게 된다.

Step 2) 거리 계산 및 분류 : 교차 전략에서 필요한 생성한 해 집단들 사이의 거리를 계산하며, 목적 함수 값을 구하여 해 집단을 4개의 그룹으로 분류(Classification)한다.

Step 3) 교차 : 나뉜 그룹에 따라 교차 전략을 수행한다. 그룹 별로 서로 다른 교차 전략을 수행하여 자식 해를 생성한다.

Step 4) 변이 : 해의 다양성을 유지하기 위하여 생성된 자식 해의 일부 유전자를 변화시킨다. 변이되는 유전자는 경계범위 내에서 무작위 값으로 생성된다.

Step 5) 대치 : 앞선 교차, 변이 단계를 거쳐 최종적으로 얻어진 자식 해들을 다음 세대의 부모 해로 사용한다. 여러 가지 대치 방법이 존재하는데 본 논문에서는 엘리트(Elite) 집단의 개념을 사용하여 그 세대의 부모 해와 생성된 자식 해들 중에서 가장 좋은 목적 함수 값을 가진 해들만을 다음 세대로 전달한다.

Step 6) 수렴 판별 : 수렴 판별은 구해진 해들이 최적 해에 수렴하였는지를 판별하는 부분으로, 본 논문에서의 해 집단의 상위 20%의 해들의 평균이 5 세대 전의 평균에 비해 허용오차(Tolerance) 이하의 변화를 보이면 수렴한 것으로 판별하였다[50].

Step 7) 위의 step 6에서 수렴되지 않은 것으로 판별되면 step 2~6까지의 과정을 매 세대마다 반복 수행하며, 수렴된 것으로 판별하면 알고리즘을 종료하고 최적 해를 구한다.

제안한 고차원 혼합 유전 알고리즘을 검증하기 위하여 여러 시험 함수들과 산란점 추출 문제에 적용하여 그 결과를 확인하였다.




그림 3.12. 혼합 유전 알고리즘의 순서도

Fig 3.12. Flowchart of hybrid GA

3.2.2 시뮬레이션 결과

최적화 알고리즘의 경우 일반적인 성능 비교를 위한 시험 함수들이 존재하며, 여러 최적화 논문에서는 몇 가지 시험 함수에 대한 성능 비교를 수행하여, 최적화 알고리즘의 성능을 평가한다[51, 52]. 먼저 일반적인 최적화 함수들에 대한 제안한 알고리즘의 성능을 비교하기 위하여 아래와 같은 7개의 시험 함수들에 대하여 최적화를 수행하였다. 표 3.2은 시험 함수들의 수식과 최적 해, 그리고 탐색 영역을 나타낸 것이다. n 은 설계 변수의 차원수를 나타낸다. 지역 최소값들이 많아 최적 해를 찾기 힘든 함수들과 해 집단의 기울기가 완만하여 정확한 최적 해를 찾기 힘든 여러 시험 함수들에 적용하여 보았다. f_1 은 Rastrigin 함수를, f_2 는 Ackley 함수를, f_3 는 Schwefel 함수를, f_4 는 Sphere 함수를, f_5 는 Zakharov 함수를, f_6 는 Rosenbrock 함수를, f_7 은 Styblinski-Tang 함수를 의미한다.

위의 시험 함수들을 그래프로 표현한 것이 그림 3.13이다. 실제 시험 함수들은 2차원 이상의 함수들이지만 그래프로 표현하기에 한계가 있으므로 2차원일 때의 함수로 나타냈다. 시험 함수들에 대하여 본 논문에서 제안한 혼합 유전 알고리즘을 적용하여 검증을 진행하였다.

표 3.2. 시험 함수

Table 3.2. Test function

시험 함수	최적 해	탐색 영역
Rastrigin $f_1(\mathbf{x}) = 10n + \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)]$	$f(0, \dots, 0) = 0$	$(x_i \in [-5.12, 5.12])$
Ackley $f_2(\mathbf{x}) = -20e^{-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}} - e^{\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$	$f(0, \dots, 0) = 0$	$(x_i \in [-32.768, 32.768])$
Schwefel $f_3(\mathbf{x}) = 418.9829n - \sum_{i=1}^n x_i \sin(\sqrt{ x_i })$	$f(420.9687, \dots) = 0$	$(x_i \in [-500, 500])$
Sphere $f_4(\mathbf{x}) = \sum_{i=1}^n x_i^2$	$f(0, \dots, 0) = 0$	$(x_i \in [-5.12, 5.12])$
Zakharov $f_5(\mathbf{x}) = \sum_{i=1}^n x_i^2 + \left(\sum_{i=1}^n 0.5ix_i\right)^2 + \left(\sum_{i=1}^n 0.5ix_i\right)^4$	$f(0, \dots, 0) = 0$	$(x_i \in [-5, 10])$
Rosenbrock $f_6(\mathbf{x}) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$f(1, \dots, 1) = 0$	$(x_i \in [-5, 10])$
Styblinski-Tang $f_7(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^n (x_i^4 - 16x_i^2 + 5x_i)$	$f(-2.903534, \dots) = -39.16599n$	$(x_i \in [-5, 5])$




그림 3.13. 혼합 유전 알고리즘의 평가를 위한 시험 함수
 Fig. 3.13. Test function for the verification of hybrid GA

결과의 비교를 위해 제안한 알고리즘이 영향을 받은 WOA와 BMO 알고리즘의 성능을 함께 확인하였다. 최적화를 위한 파라미터 설정은 표 3.3과 같다. 고차원 최적화 성능을 알아보기 위해 설계변수의 수를 100으로 설정하였다. 세대 수는 100으로 두었으며, 종료 조건을 만족하면 바로 수렴되도록 하였다. 인구 수는 200으로 두었으며 4개의 그룹 별로 best 그룹은 10, local 그룹은 80, global 그룹은 100, random 그룹은 10으로 두었다.

표 3.3. 최적화 파라미터

Table 3.3. Parameter of optimization

설계변수	100
세대 수	100
인구 수	200 (best 그룹 : 10, local 그룹 : 80, global 그룹 : 100, random 그룹 : 10)
종료조건 허용오차	0.001

표 3.4는 시험 함수들의 최적화 결과를 나타낸 것이다. Rastrigin, Ackley, Sphere와 같은 시험 함수에서 WOA가 더 정확한 목적함수 값을 찾는 것을 확인할 수 있다. 하지만 이미 목적함수 값의 0에 가까우므로 유의미한 차이는 아닌 것으로 볼 수 있다. 그와 다르게, Schwefel, Zakharov, Styblinski-Tang 함수에서 제안한 혼합 유전 알고리즘이 다른 알고리즘에 비해 훨씬 좋은 해를 찾는 것을 확인할 수 있으며, 함수호출 수도 적은 것을 확인할 수 있다. BMO의 경우 전체적으로 제안한 혼합 유전 알고리즘 보다 성능이 떨어지는 것을 확인할 수 있다. 그러므로, 제안한 알고리즘이 고차원 최적화에 다른 알고리즘에 비해 훨씬 적합한 것을 확인할 수 있다.

표 3.4. 시험 함수들의 최적화 결과

Table 3.4. Optimization results of test functions

시험 함수		WOA	BMO	Hybrid GA
Rastrigin	목적함수 값	2.160E-14	6.048+E2	9.937E-10
	함수호출 수	19,552	21,200	20,200
Ackley	목적함수 값	1.397E-10	2.077E+1	1.592E-6
	함수호출 수	20,000	1,957.7	20,200
Schwefel	목적함수 값	5.783E+3	2.838E+4	8.384E+2
	함수호출 수	12,726	20,240	9,576
Sphere	목적함수 값	5.114E-21	3.135E+1	6.062E-13
	함수호출 수	20,000	20,830	20,200
Zakharov	목적함수 값	1.623E+3	1.415E+3	1.388E+3
	함수호출 수	19,668	19,197	3,454
Rosenbrock	목적함수 값	9.813E+1	7.881E+4	9.802E+1
	함수호출 수	7,262	19,640	8,910
Styblinski-Tang	목적함수 값	-3.763E+3	-1.981E+3	-3.900E+3
	함수호출 수	9,308	18,342	6,254

다음으로 실제 산란점 추출 문제에 적용한 결과를 확인해 보았다.

표적으로부터 수신되는 신호 S_r 는 아래의 수식 (3.14)와 같이 표현할 수 있다. (x_m, y_m) 은 관측 위치를 나타내며, f_n 은 n 번째 주파수, σ_i 는 i 번째 산란점의 반사계수, R_i 는 i 번째 산란점과 관측 위치의 거리를 나타낸다. N은 표적의 산란점의 수를 나타낸다.

$$S_r(x_m, y_m, f_n) = \sum_{i=1}^N \sigma_i e^{-jk_n(2R_i)} \quad (3.14)$$

최소화하려는 목적함수는 아래의 수식 (3.15)과 같다. $S_E(\sigma)$ 는 설계변수로 사용된 반사계수 벡터 σ 를 통해 구해진 수신 신호를 나타낸다.

$$f(\sigma) = \min \left\{ \sum_{f_n} |S_r(x_m, y_m, f_n) - S_E(\sigma)| \right\} \quad (3.15)$$

아래의 그림 3.14는 추출하려는 산란점의 위치와 반사계수를 나타낸 것이다. 알파벳 ‘A’의 형태를 가진 표적에 대하여 WOA와 BMO, 그리고 제안한 고차원 혼합 유전 알고리즘으로 산란점을 추출한 결과 그림 3.15와 같은 추정 산란점을 획득하였다. 결과를 확인해 보면 다른 최적화 알고리즘에 비해 제안한 혼합 유전 알고리즘이 표적의 산란점 위치와 반사계수를 잘 찾는 것을 확인할 수 있었다.






그림 3.14. ‘A’ 형태의 표적


Fig. 3.14. ‘A’ shaped target



(a)



(b)



(c)

그림 3.15. (a) WOA로 추정된 산란점 (b) BMO로 추정된 산란점
제안한 혼합 유전 알고리즘으로 추정된 산란점

Fig. 3.15. (a) Estimated scatterers (WOA) (b) Estimated scatterers
(BMO) (c) Estimated scatterers (Proposed hybrid GA)

다음으로 다른 표적들에도 적용하여 그 결과를 확인해 보았다. 그림 3.16는 알파벳 ‘A’ , ‘O’ , ‘F’ 의 형태를 가지는 세 가지 표적에 대하여 최적화를 수행한 결과이다. 표적들의 산란점들을 잘 추정하는 것을 확인할 수 있다. 그러므로 제안한 혼합 유전 알고리즘은 산란점 추출 문제에 잘 적용됨을 알 수 있다.




그림 3.16. (a) ‘A’ 형태의 표적 (b) 추정된 산란점 (c) ‘O’ 형태의 표적
(d) 추정된 산란점 (e) ‘F’ 형태의 표적 (f) 추정된 산란점

Fig. 3.16. (a) ‘A’ shaped target (b) Estimated scatterers (c)
‘O’ shaped target (d) Estimated scatterers (e) ‘F’ shaped target (f)
Estimated scatterers

제 4 장 최적의 산란점 추출 및 식별

앞서 연구한 산란점 추출 알고리즘을 통해 표적의 특성을 반영하는 산란점 정보를 추출해 낼 수 있다. CS 기반의 산란점 추출 기법의 경우, 선택되는 관측 방위각과 수에 따라 추출되는 산란점 정보의 정확도가 달라지게 된다. 고차원 혼합 유전 알고리즘 기반의 산란점 추출은 연산 시간이 오래 걸린다. 이러한 단점들을 개선하기 위하여 앞서 연구한 산란점 추출 알고리즘들을 결합한 최적의 산란점 추출 기법에 대한 연구를 진행하였다. 다음으로 식별 알고리즘의 식별기들에 대한 연구를 진행하였으며, SVM의 최적화를 이용한 식별 알고리즘을 연구하고 성능을 비교하였다. 최적의 산란점 추출 기법과 식별 성능을 검증하기 위하여 수치해석 기법으로 얻어진 시뮬레이션 데이터와 실제 측정 실험 데이터를 이용하여 표적 식별이 성공적으로 수행되는 것을 확인하였다.


4.1 최적의 산란점 추출 기법

산란점 추출 기법으로 연구된 CS 기반의 산란점 추출 기법의 경우 임의로 선택되는 관측 방위각에 따라 추출되는 산란점 정보의 정확도가 달라지며, 관측 방위각의 수에 따라서 성능이 달라지게 된다.


아래의 그림 4.1은 3.1.3절의 시뮬레이션 상황에서 관측 방위각의 수 $L=6, 4, 3$ 일 때의 산란점 추출 결과를 나타낸 것이다. 관측 방위각을 적게 선택할수록, 정보가 적어지기 때문에 보다 정확한 산란점이 추출하기 어렵다. $L=6$ 일 때의 추출 결과인 그림 4.1(a)는 반사 계수 정보는 잘 추출하나, 산란점 주변의 픽셀에서 어느 정도의 열화가 발생하는 것을 확인할 수 있다. 그림 4.1(b)는 $L=4$ 일 때의 산란점 추출 결과로 일부 산란점의 반사 계수 값에서 오차가 발생하는 것을 확인할 수 있다. 그림 4.1(c)는 $L=3$ 일 때의 산란점 추출 결과로 일부 산란점의 경우 위치를 찾지 못하며, 반사 계수의 정확도가 크게

줄어들었다. 연산 시간은 방위각 6개의 경우 약 0.2735초, 4개의 경우 약 0.2186초, 3개의 경우 0.1983초가 걸렸다. 사용되는 방위각 정보가 많아질수록, 연산 행렬의 크기의 증가로 인해 연산 시간이 증가하기 때문이다. 그러므로 더 적은 관측 각을 사용할수록 연산 시간을 절감시킬 수 있으며, 관측 방위각이 적을 때에도 정확한 산란점 정보를 추출할 수 있는 기법에 대한 연구가 필요하다.


그리고 공대공 표적 식별과 같은 상황에서는 표적의 정보를 획득할 수 있는 관측 방위각이 제한되어 있으므로, 관측 방위각이 적어도 정확한 산란점 정보를 추출할 수 있는 알고리즘에 대한 연구가 필수적이다. 본 장에서는 기존의 CS 기반의 산란점 추출에서 발생하는 이러한 문제점을 보완하기 위하여 최적화 기반의 산란점 추출 방법을 결합하는 기법을 결합한 최적의 산란점 추출 기법을 제안하였다.



(a)



(b)



(c)

그림 4.1. (a) 표적의 산란점(향상된 OMP, $L=6$) (b) 표적의 산란점(향상된 OMP, $L=4$) (c) 표적의 산란점(향상된 OMP, $L=3$)

Fig. 4.1. (a) Scatterers of the target(Improved OMP, $L=6$) (b) Scatterers of the target(Improved OMP, $L=4$) (c) Scatterers of the target(Improved OMP, $L=3$)

4.1.1 산란점 추출 기법

향상된 OMP 알고리즘을 이용한 산란점 추출 방법의 경우 측정 데이터를 줄일 수 있으나, 제한된 관측 각으로 인해 산란점 정보의 정확성이 떨어지게 된다. 고차원 혼합 유전 알고리즘을 이용한 산란점 추출 방법은 보다 정확한 산란점 정보를 추출할 수 있지만, 알고리즘 수행 시간이 매우 오래 걸린다. 두 알고리즘의 장점만을 취하기 위해, 다음 그림 4.2와 같은 산란점 추출 방법을 제시하였다. 표적으로부터 수신된 신호에 향상된 OMP 알고리즘을 적용하여 산란점 정보를 추출한다. 다음으로 추출된 산란점 정보를 초기 해로 하여 혼합 유전 알고리즘을 수행한다. 이와 같이 추출된 산란점 정보를 초기 해로 설정하면, 기존의 혼합 유전 알고리즘으로 산란점 추출하는 것에 비해 수렴성이 증가하며, 더 정확한 해를 찾을 수 있다. 최적의 산란점 추출 기법의 검증을 위해 그림 4.1(c)의 관측 방위각이 3개 일 때의 데이터를 이용하여 산란점 추출을 수행하였다. 목적함수는 아래의 수식 (4.1)과 같다. φ_l 는 l 번째 관측각을 의미하며, $r(\varphi_l)$ 는 l 번째 관측각에서 얻어진 수신 신호를, $(\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma})$ 는 설계변수인 산란점의 위치와 반사계수를 의미한다. r_E 는 추정된 수신 신호를 의미하며, L 는 관측각의 수이다.

$$f(\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \min \left\{ \sum_{l=1}^L |IDFT[r(\varphi_l)] - IDFT[r_E(\varphi_l, \mathbf{x}, \mathbf{y}, \boldsymbol{\sigma})]| \right\} \quad (4.1)$$

그림 4.3은 최적의 산란점 추출 기법을 적용한 결과이다. 그림 4.3(a)는 최적화 5세대 후의 산란점 추출 결과를 나타낸 것이며, 그림 4.3(b)는 최적화가 완료된 후의 결과이다. 세대가 지날수록 산란점의 위치를 잘 찾아가는 것을 확인할 수 있다. 그림 4.3(b)의 결과와 그림 4.1(c)의 결과를 비교해 보면 제안한 최적의 산란점 추출 기법을 통해 보다 정확한 산란점 정보를 추출하는 것이 가능함을 알 수 있다.





그림 4.2. 최적의 산란점 추출 기법

Fig. 4.2. Technique for optimal extraction of scattering center


그림 4.4는 최적화 알고리즘의 수렴 곡선을 나타낸 것이다. 그림 4.4(a)는 향상된 OMP로 얻은 산란점 정보를 초기 해로 주지 않은 경우의 수렴 곡선이며, 그림 4.4(b)는 획득한 산란점 정보를 초기해로 두었을 때의 수렴 곡선이다. 초기 해를 주지 않은 경우에는 50 세대를 넘어가도 최적 해에 수렴이 되지 않는 것을 확인할 수 있었다. 그에 비해 초기 해를 주는 경우에는 13 세대 정도부터 최적 해에 가까이 수렴하는 것을 확인할 수 있으며, 이것으로 보아 수렴 속도가 매우 증가하였음을 확인할 수 있다. 임의의 초기 해를 사용할 경우 약 1.5354초의 연산 시간이 걸렸으며, 향상된 OMP를 통해 얻은 산란점 정보를 초기 해로 최적화를 수행하였을 때는 약 0.3992초의 연산 시간이 걸려, 64.87%의 연산 시간이 줄어들었다. 최적화를 수행하여 증가하는 연산 시간을 크게 줄일 수 있음을 알 수 있다. 이와 같이 최적의 산란점 추출 기법으로 추출된 산란점 정보를 이용하여 표적 식별을 수행하면, 높은 식별률을 보일 것으로 생각된다.

지금까지 시뮬레이션에 사용된 표적은 이상적인 점 표적들로

이루어진 표적이다. 다중 경로와 측정 방위각에 의해 가려지는 산란점들을 제대로 반영하지 않은 레이더 수신 신호로, 실제 측정으로 얻어지는 레이더 수신 신호와 다르다. 실제 표적에의 적용 가능성을 확인하기 위하여 실제 비행기 모델들의 레이더 수신 신호를 수치해석적 기법으로 획득한 데이터에 적용하여 보았다.




(a)




(b)

그림 4.3. 최적의 산란점 결과 (a) 향상된 OMP+최적화(5세대 후) (b) 향상된 OMP+최적화

Fig. 4.3. Result of optimal scattering center (a) Improved OMP+optimization (after 5 generations) (b) Improved OMP+optimization



(a)



(b)

그림 4.4. (a) 수렴 곡선(임의의 초기해) (b) 수렴 곡선(향상된 OMP로 얻은 초기해)

Fig. 4.4. (a) Convergence curve (random initial solution) (b) Convergence curve (initial solution obtained by improved OMP)

4.1.2 시뮬레이션 결과

앞서 사용된 표적의 경우 이상적인 점 표적으로 구성되어 있으며, 산란점들 사이의 다중 경로와 관측 방위각에 의한 영향들을 고려하지 않은 수신 신호를 생성하였다. 그러므로 실제 표적에 적용하는데 적합한지에 대한 검증이 되지 않는 상태이다. 이에 대한 검증을 위하여 본 장에서는 실제 표적의 형태를 가지는 모델에 대한 수신 신호를 생성하고 산란점 추출 알고리즘을 적용하였다. 사용된 표적의 모델은 그림 4.5에 나타나 있다. 3 종류의 비행기 표적의 모델로 아래의 표 4.1의 시뮬레이션 조건에서 수치해석기법 중의 하나인 물리광학법(PO : Physical Optics)을 적용하여 데이터를 획득하였다[53, 54].




그림 4.5. (a) A-380 캐드 모델 (b) 유로파이터 캐드 모델 (c) F-15 캐드 모델


Fig. 4.5. (a) CAD model of A-380 (b) CAD model of Eurofighter (c) CAD model of F-15

표 4.1. 시뮬레이션 환경


Table 4.1. Simulation environment

주파수	8~12 GHz
편파	VV 편파
샘플링 수	1024
고각	90°
방위각	-90~90° (1° 간격)
모델 크기(A-380)	650×580 [mm]
모델 크기(Eurofighter)	500×350 [mm]
모델 크기(F-15)	600×400 [mm]


물리광학법으로 얻어진 3종류 표적의 HRRP 데이터는 그림 4.6에 나타나 있다. 얻어진 HRRP 데이터를 FBP(Filtered back-projection) 알고리즘에 적용하여 영상을 복원하였다[55, 56]. 사용한 필터는 Shepp-Logan 필터를 사용하였으며, 복원된 SAR 영상은 산란점 추출 알고리즘을 통해 얻어진 산란점 정보와의 비교에 사용되었다. 복원된 FBP 알고리즘의 결과는 그림 4.7에 나타나 있다.



(a)




(b)




(c)

그림 4.6. (a) A-380 HRRP (b) 유로파이터 HRRP (c) F-15 HRRP


Fig. 4.6. (a) HRRP of A-380 (b) HRRP of Eurofighter (c) HRRP of F-



(a)



(b)



(c)

그림 4.7. (a) A-380의 복원된 영상 (b) 유로파이터의 복원된 영상 (c) F-15의 복원된 영상

Fig. 4.7. (a) Reconstructed image of A-380 (b) Reconstructed image of Eurofighter (c) Reconstructed image of F-15

검증을 위해 먼저 3.1.2에서 제안한 향상된 OMP 알고리즘으로 산란점 추출을 수행하였다. 임의의 12개의 관측 방위각에서 데이터를 획득하였으며, 아래의 그림 4.8과 같은 산란점 정보를 획득할 수 있다.

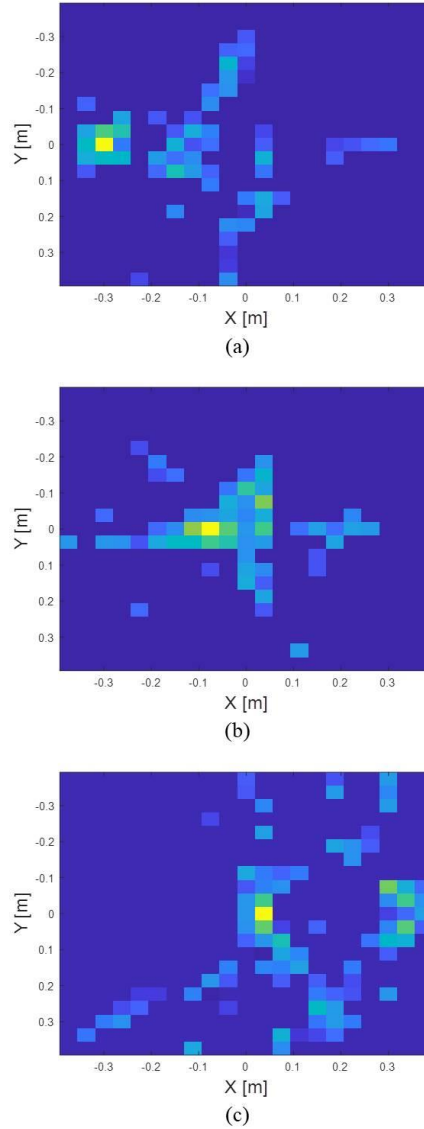


그림 4.8. 추출된 산란점 (향상된 OMP, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15

Fig. 4.8. Extracted scattering center (Improved OMP, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

획득한 산란점 정보에 혼합 유전 알고리즘 기반의 산란점 추출 알고리즘을 적용하면 그림 4.9의 결과를 획득할 수 있다.




그림 4.9. 추출된 산란점 (향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) 유로파이터 (c) F-15

Fig. 4.9. Extracted scattering center (Improved OMP+optimization, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

향상된 OMP만을 적용한 결과에 비해 최적화를 결합한 결과가 SAR 영상과 더 유사한 것을 확인할 수 있다. 그러므로 제안한 최적의 산란점 추출 기법이 표적의 산란점 정보를 잘 추출한다고 볼 수 있다. 획득한 산란점 정보를 이용하여 표적 식별을 수행하기에 앞서 표적 식별 알고리즘에 대한 연구를 다음 절에서 진행할 것이다.

4.2 식별 알고리즘

식별 알고리즘은 표적 신호 수신, 특징점 추출, 식별기를 이용한 표적 식별, 판별의 단계로 이루어져 있다. 그 중 특징점 추출 단계는 표적 식별 성공률에 큰 영향을 미친다. 기존의 특징점 추출 기법으로는 principal component analysis (PCA)와 linear discriminant analysis (LDA) 기법이 있으며, 레이더 표적 식별에서 주로 사용된다[57-60]. PCA는 데이터를 압축할 수 있는 새로운 좌표축으로의 변환을 통해 데이터의 차원수를 줄여 연산량을 감소시킬 수 있다. LDA는 데이터의 구별성을 높일 수 있는 새로운 좌표축으로의 변환을 통해 식별 성공률을 향상시킬 수 있다. [61]에 따르면 PCA와 LDA를 모두 적용하는 것이 표적의 식별률을 더 높일 수 있는 방법이다. 본 논문에서도 앞서 얻어진 산란점 데이터에 PCA와 LDA를 적용하여 특징점을 추출하고 표적 식별을 수행하였다.

4.2.1 식별기 연구

식별기 단계에서는 어떤 식별기를 사용하느냐에 따라 식별 성능이 달라지게 된다. 일반적으로 많이 사용되는 식별기로 k-NN, Bayes, SVM 등이 있으며, 세 식별기의 성능에 대한 분석을 진행하였다.

추출된 산란점을 특징점으로 표적 식별을 수행하였는데, 표적 식별에 사용되는 식별기의 종류에 따라 식별 성능이 달라지게 된다. 레이더 표적 식별에 주로 사용하는 식별기로는 k-NN, Bayes, 서포트 벡터

머신(SVM : Support Vector Machine) 등이 있다[62-70]. k-NN 식별기는 측정한 데이터와 표적 DB와의 거리를 구하여, 가장 가까운 k 개의 표적들의 클래스로 분류하는 방법이다. Bayes 식별기는 Bayes 룰에 기반하여 표적을 분류하는 식별기이며, SVM 식별기는 표적을 클래스에 따라 구분하는 초평면을 설정한다. k-NN은 구현이 간단하지만, 저차원 데이터의 식별에 적합하고 DB 구조에 영향을 크게 받기에 본 논문에서 사용하기에는 적합하지 않다. Bayes 식별기는 적은 양의 DB로도 잘 동작하지만, 데이터의 분포에 따른 성능 변동이 있으며, 데이터가 가우시안 분포를 갖지 않는 경우 식별 성능이 저하되는 문제가 있다. SVM은 커널 함수를 이용하여 비선형 분류가 가능하며, 고차원 데이터를 식별하는데 적합한 반면, 학습 속도가 떨어진다는 문제가 있다. 본 논문에서는 고차원 식별에 적합하고 커널 및 커널 파라미터 최적화를 이용한 식별 성능 향상이 가능한 SVM을 식별기로 선택하여 표적 식별을 수행하였으며, 기존의 방법에 비해 더 좋은 식별 성능을 가지는 것을 확인하였다. 다음으로 SVM 식별기의 기본 개념에 대하여 설명하려 한다.

4.2.2 Support vector machine을 이용한 식별 알고리즘

표적 식별에서 주로 사용되는 식별기 중 하나인 SVM은 기계학습의 하나로, 다양한 분야에서 많이 사용되어 왔다[71-73]. 앞서 언급한 것과 같이 SVM 식별기의 경우 고차원 식별에 적합하며, 최적화를 통해 DB에 맞게 식별 성능을 향상시킬 수 있다. 본 논문에서는 이러한 SVM을 이용하여 표적 식별을 수행하였다.

기본적인 선형 SVM은 특징점 공간에서 두 클래스의 데이터를 구분할 수 있는 최적의 초평면(Hyperplane)을 설정한다. 두 클래스의 점들 \mathbf{x}_i 가 벡터 공간에 주어지고, 두 클래스가 벡터 공간에서 서로 다른 영역에 존재한다고 가정하면, 아래의 그림 4.10과 같이 두 클래스는 초평면을 이용하여 선형적으로 분류가 가능하다.




그림 4.10. 초평면에 의한 분류

Fig. 4.10. Classification by hyperplane

원점을 지나는 초평면의 방정식은 $\mathbf{w}^T \mathbf{x} = 0$ 으로 둘 수 있고, 일반화하여 원점을 지나지 않는 초평면의 방정식은 $\mathbf{w}^T \mathbf{x} + b = 0$ 로 둘 수 있다. 이 평면의 법선 벡터를 \mathbf{w} 라 하면, 이 법선 벡터 \mathbf{w} 와 원점으로부터 각각의 데이터 점들까지의 벡터가 이루는 각이 90도 미만이라면 클래스 A로, 90도 이상이라면 클래스 B로 분류 가능하다. 이를 수식으로 표현하면 아래의 식 (4.2)과 같다. $\langle \cdot \rangle$ 는 두 벡터의 내적을 의미한다.

$$\begin{cases} \langle \mathbf{w}, \mathbf{x} \rangle + b \leq 0, \text{ then 'A' } \\ \langle \mathbf{w}, \mathbf{x} \rangle + b \geq 0, \text{ then 'B' } \end{cases} \quad (4.2)$$

결국, 모든 데이터들을 해당 클래스에 맞게 분류하면서, 초평면에 가장 가까운 데이터들과는 최대한 멀리 떨어지도록 초평면을 설정하는 것이 가장 주요한 문제이다. 그러므로 아래 그림 4.11과 같이 초평면에 가장 가까운 데이터와 분리 초평면 사이의 마진 d 를 최대화시켜야

한다.




그림 4.11. 초평면 선택

Fig. 4.11. Hyperplane selection

마진 d 는 아래의 수식 (4.3)와 같이 구해지게 된다[74].

$$d = \frac{2}{\|w\|^2} \quad (4.3)$$

결국, $\|w\|^2$ 최소화 문제가 된다. 그리고 앞서 본 것처럼 두 클래스에 따라 데이터들이 분류되어야 하므로, 마진 초평면을 $w^T x + b = \pm 1$ 로 두고 데이터들을 클래스에 따라 $y_i \in \{+1, -1\}$ 에 배정하면, 아래의 수식 (4.4)과 같은 제약조건을 만족시켜야 한다.

$$y_i(w^T x_i + b) \geq 1 \quad (4.4)$$

수식 (4.3)와 같은 최소화 문제를 풀면서, 수식 (4.4)의 제약조건을 만족시켜야 하는데, 이러한 문제는 라그랑주 승수법(Lagrange

Multiplier Method)을 이용하여 풀 수 있다[75, 76]. 그 식은 아래의 수식 (4.5)와 같다.

$$L(\mathbf{w}, b, \alpha) = \frac{\|\mathbf{w}\|^2}{2} - \sum_{i=1}^P \alpha_i (y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1) \quad (4.5)$$

$$s. t. y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, \dots, P$$

라그랑지안 L 은 변수 \mathbf{w}, b 에 대하여 최소화되어야 하며, 변수 $\alpha_i \geq 0$ 에 대하여는 최대화되어야 한다. 최소화를 풀기 위해, 변수 \mathbf{w}, b 로 L 을 편미분하면 아래의 수식 (4.6)를 얻을 수 있다.

$$\frac{L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^P \alpha_i y_i \mathbf{x}_i = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \quad (4.6)$$

$$\frac{L(\mathbf{w}, b, \alpha)}{\partial b} = \sum_{i=1}^P \alpha_i y_i = 0$$

변수 \mathbf{w} 가 데이터들의 선형 합으로 나타나므로, α_i 를 구하면 변수 \mathbf{w} 를 구할 수 있다. 위의 식 (4.6)를 식 (4.5)에 적용하면 아래의 수식을 얻을 수 있다.

$$L(\mathbf{w}, b, \alpha) =$$

$$\frac{1}{2} \left(\sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \right) \left(\sum_{j=1}^P \alpha_j y_j \mathbf{x}_j \right) - \left\langle \left(\sum_{i=1}^P \alpha_i y_i \mathbf{x}_i \right), \left(\sum_{j=1}^P \alpha_j y_j \mathbf{x}_j \right) \right\rangle - \quad (4.7)$$

$$\left(\sum_{i=1}^P \alpha_i y_i b \right) + \sum_{i=1}^P \alpha_i = \sum_{i=1}^P \alpha_i - \frac{1}{2} \left(\sum_{i=1}^P \sum_{j=1}^P \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \right)$$

최종적으로 L 은 변수 α 에 대한 최대화 문제가 된다. Quadratic 프로그래밍 기법을 이용하면 α 를 구할 수 있으며, 구해진 α 를 이용하여 \mathbf{w}, b 를 순차적으로 구할 수 있다[77]. 구해진 α 중 0이 아닌 값을 가지는 데이터만 \mathbf{w} 를 구하는데 의미가 있으며, 이러한 데이터들을 support vector라 부른다.

비선형 SVM은 선형적으로 분리되지 않는 데이터들을 고차원으로의 매핑을 통해 선형적으로 분리 가능하도록 하는 방법이다. 기존의 선형적으로만 분리가 가능한 SVM과 다르게 데이터들을 비선형적으로 분리하는 효과를 줄 수 있다[78, 79]. 예를 들어 2차원에서는 선형적으로 분리되지 않는 데이터들을 3차원으로 매핑하면 그림 4.12와 같이 선형적으로 분리 가능하게 할 수 있다.




그림 4.12. 비선형 SVM

Fig. 4.12. Non-linear SVM

이런 비선형 SVM은 차원이 높아지기 때문에 연산량이 증가하는 문제가 발생한다. 이러한 문제를 해결하기 위해 커널 트릭(Kernel trick)을 이용한다[80, 81]. SVM에서는 벡터들의 내적 값을 계산하게 되는데 비선형 매핑 함수 ϕ 를 구하지 않고 커널 함수 $\phi(x_i)^T \phi(x_j) = K(x_i, x_j)$ 를 이용해 연산량을 증가시키지 않고도 SVM 연산을 수행할 수 있다. 주로 사용되는 커널 함수로는 linear, radial basis function(RBF), polynomial, sigmoid 등이 있다. 아래의 표 4.2는 커널 함수의 종류들과 정의를 나타낸 것이다.

표 4.2. 커널 함수

Table 4.2. Kernel Functions

Linear	$K(x_i, x_j) = \langle x_i, x_j \rangle$
Polynomial	$K(x_i, x_j) = (\langle x_i, x_j \rangle + c)^d$
RBF	$K(x_i, x_j) = \gamma e^{\frac{-\ x_i - x_j\ ^2}{2\sigma^2}}$
Sigmoid	$K(x_i, x_j) = \tanh(\eta \langle x_i, x_j \rangle + v)$

어떤 커널 함수를 사용하는지에 따라 식별기의 성능이 달라지며, 같은 커널 함수에서도 파라미터를 어떻게 설정하는지에 따라 성능이 달라지게 된다. 최근 이러한 커널 함수와 파라미터 선택에 대한 연구들이 많이 진행되고 있는데, 커널 함수의 파라미터를 최적화하는 연구부터 여러 커널 함수들을 합성하여 새로운 커널 함수를 생성하는 연구도 진행되고 있다[82-86]. SVM의 커널 함수는 식별하려는 표적과 DB에 의존적이므로, DB가 변경되면 최적의 파라미터도 바뀌게 된다. 그러므로 본 논문에서는 최적화 알고리즘을 통한 커널 함수의 최적화를 선택하였다. 커널 함수의 파라미터들을 설계변수로 하여 DB에 맞게 최적화를 진행하여 적합한 커널 함수를 선택하고 최적화된 파라미터를 획득하였다, 이와 같이 SVM 식별기는 다른 식별기에 비해 성능이 우수하며, 최적화를 통해 식별 성능을 향상시킬 수 있다. 이러한 SVM 식별기의 우수성에 대한 검증을 아래에서 진행하였다.

기존의 다른 식별기에 비해 SVM이 우수함을 검증을 위해 아래의 그림 4.13과 같은 간단한 3 종류의 표적에 대하여 식별을 수행하였다. Down-scale된 3 종류의 표적들로 3.5×1.3×1 m의 제트 스키(표적1), 5 × 1.5 × 1 m의 선박(표적2), 최대 반지름 0.1 m, 높이 1 m의 잠망경(표적3)이 사용되었다. 고각은 90 도로 고정시켜 두고, 방위각

-30~30도, VV-편파, 주파수 S-밴드^[1], 주파수 샘플링 수 121개의 조건에서 표적의 RCS 데이터를 획득하였다.





그림 4.13. 식별 표적 (a) 표적 1(제트 스키) (b) 표적 2(선박) (c) 표적 3(잠망경)


Fig. 4.13. Target of identification (a) Target 1(Jet ski) (b) Target 2(Ship) (c) Target 3(Periscope)

획득한 RCS의 DB는 아래의 그림 4.14와 같이 나타난다. 얻어진 RCS 데이터를 주파수와 방위각 별로 나타낸 DB로, 실제 측정에서는 측정 방위각에서 주파수 별 RCS 값들이 얻어지게 된다.


[1] 보안 상의 이유로 구체적 주파수 밴드 생략



(a)



(b)



(c)

그림 4.14. 표적 DB (a) 표적 1 (b) 표적 2 (c) 표적 3

Fig. 4.14. Target DB (a) Target 1 (b) Target 2 (c) Target 3

획득한 RCS 데이터를 이용하여 표적 식별을 수행하였다. 본 논문에서는 DB를 학습과 검증 2 분류로 나누어 식별을 수행하는 홀드아웃 검증을 사용하였다[87]. 얻어진 DB를 학습에 사용하였으며, 식별을 위한 검증 데이터로 각 방위각에 따라 얻어지는 주파수에 따른 RCS 정보에 화이트 가우시안 잡음을 추가하여 검증 DB를 생성하였다.

세 식별기의 성능을 분석하기 위하여 k-NN, Bayes, SVM 식별기의 성능을 잡음의 SNR(Signal-to-Noise Ratio)을 변화시켜 가며 확인하였다. SNR을 0~50 dB까지 변화시켰으며, 1000번 수행하여 식별 성공률을 계산하였다. 특징점 추출에 사용된 PCA의 차원 수는 10, LDA의 차원 수는 5이며 그 결과는 아래의 그림 4.15와 같았다.

결과를 확인해 보면 세 식별기 중 SVM이 잡음에 가장 강한 것을 볼 수 있다. 또한 식별기의 성능은 특징점 추출 기법인 PCA와 LDA를 적용할 때 차원 수를 어떻게 설정하는지에 따라 달라진다. 이러한 차원 수를 유전 알고리즘을 통해 최적화 하면 아래의 그림 4.16의 결과를 얻을 수 있다. 앞서 얻어진 그림 4.14의 DB를 이용하여 표적 식별을 수행하였으며, 식별기로 SVM을 사용하였다. PCA의 차원 수 n_{PCA} 와 LDA의 차원 수 n_{LDA} 를 설계 변수로 하여 최적화를 수행하였으며, 그 결과 $n_{PCA} = 11, n_{LDA} = 11$ 일 때 SNR이 약 5 dB 더 낮아도, 최적화 전에 비해 식별 성공률이 높게 나오는 것을 확인할 수 있다. PCA, LDA의 최적화는 DB에 의존적이므로 표적의 DB가 바뀌면 새로 최적화를 수행할 필요가 있다.






그림 4.15. SNR에 따른 식별 결과 (a) k-NN (b) Bayes (c) SVM

Fig. 4.15. Identification result according to SNR (a) k-NN (b) Bayes (c) SVM





그림 4.16. PCA, LDA의 최적화

Fig. 4.16. Optimization of PCA, LDA

위의 결과로 보아 SVM 식별기를 사용하며, 얻어진 DB에 맞춰 PCA, LDA의 차원 수를 최적화하면 더 나은 식별 결과를 얻을 수 있음을 알 수 있다. 다음으로 앞서 설명한 SVM 식별기의 커널 함수와


파라미터를 최적화하는 과정을 설명할 것이다.

앞서 사용한 그림 4.14의 DB를 이용하였으며, 표 4.2에 나타난 SVM의 4 종류 커널 함수들에 대한 최적화를 진행하였다. 선택된 커널 함수와 그 파라미터를 설계 변수로 하여 최적화를 진행한 결과 최적의 식별 성능을 보인 커널 함수는 polynomial 함수이며, 파라미터 $c=3.93$, $d=1$ 일 때 가장 높은 식별 성능을 보였다. 그 결과는 아래의 그림 4.17과 같다.

검증용 DB를 생성하기 위하여 방위각에 따른 주파수 별 RCS 데이터에 SNR 20 dB의 잡음을 추가하였다. 그리고 측정 방위각 별로 학습 DB와의 식별을 1000회 수행하였으며, 식별 성공률을 나타낸 것이다. 커널 파라미터를 최적화 하기 전의 식별 결과를 보면, 방위각 -8° 에서 표적 2의 식별에 항상 실패하였으며, 표적 3의 경우 3개의 측정 방위각에서 약 10% 정도 실패율을 보이는 것을 볼 수 있었다. 여기서 커널 함수 최적화를 거친 후에는 모든 측정 방위각에서 식별이 성공하는 것을 확인할 수 있었다.

이와 같이 SVM 식별기가 k-NN, Bayes 식별기에 비해 잡음에 강하며, 최적화를 통해 높은 식별률을 보임을 확인하였다. 본 논문에서는 SVM 식별기를 이용한 표적 식별을 수행할 것이며, PCA, LDA 최적화와 SVM 커널 함수 최적화를 진행하여 식별 성공률을 높였다.

측정 방위각에 따른 식별 결과



최적화

측정 방위각에 따른 식별 결과




그림 4.17. 커널 함수 최적화

Fig. 4.17. Optimization of kernel function

4.3 시뮬레이션 및 실험 결과

앞서 연구한 최적의 산란점 추출 기법으로 산란점 정보를 추출한 후, 최적화된 SVM 표적 식별을 수행하여 그 결과를 확인하였다. 먼저 앞서 시뮬레이션으로 얻어진 산란점 정보를 이용한 표적 식별을 수행한 후, 실제 측정 데이터를 이용한 산란점 추출과 표적 식별을 수행하였다.

4.3.1 시뮬레이션 결과

앞서 4.1.2절에서 획득한 3종류의 비행기 표적의 산란점 정보를 이용하여 표적 식별을 수행하였다. 최적의 산란점 추출 기법으로 추출한 산란점의 경우 선택되는 관측 방위각의 수와 위치에 따라 다르게 얻어진다. 그러므로 여러 번의 산란점 추출을 수행한 후 데이터베이스를 구축하였다. 개별 표적마다 임의의 12 개의 관측 방위각의 수신 신호로부터의 산란점 추출 알고리즘을 30번 수행하고 홀드아웃 검증을 위해 홀수 번째 데이터 15개를 학습용으로 사용하였으며, 짝수 번째 데이터 15개를 검증용으로 사용하였다.

SVM의 성능은 PCA, LDA 차원 수에 따라 달라지며, 선택하는 커널 함수와 파라미터에 영향을 받는다. 본 논문에서는 RBF 커널 함수를 사용하였으며, 아래의 수식과 같이 PCA, LDA 차원수와 커널 함수 파라미터를 최적화하였다. n_{PCA}, n_{LDA} 는 각각 PCA, LDA의 차원수를 나타내며, γ, σ 는 표 4.2에 나타난 RBF 커널 함수의 파라미터이다. M은 검증에 사용된 데이터의 수를 나타내며, δ_i 는 i 번째 검증용 데이터로 SVM 식별을 100번 수행하여 얻어진 식별 성공률을 나타낸다.

$$f(n_{PCA}, n_{LDA}, \gamma, \sigma) = \min \left\{ - \sum_{i=1}^M \delta_i(n_{PCA}, n_{LDA}, \gamma, \sigma) \right\} \quad (4.8)$$

표 4.3는 사용된 유전 알고리즘의 파라미터를 나타낸 것이며, 그림 4.18은 수렴 곡선을 나타낸 것이다. 7세대만에 수렴하는 것을

확인하였다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 10, n_{LDA} = 7$ 이 선택되었으며, 커널 파라미터는 $\gamma = 0.2511, \sigma = 1.1546$ 으로 설정되었다. 그림 4.19와 4.20은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

표 4.3. 유전 알고리즘의 파라미터

Table 4.3. Parameters of Genetic algorithm

인구 수	50
세대 수	50
설계변수	4 ($n_{PCA}, n_{LDA}, \gamma, \sigma$)
탐색 영역	$2 \leq n_{PCA} \leq 30,$ $2 \leq n_{LDA} \leq 30,$ $10^{-9} \leq \gamma \leq 10,$ $10^{-9} \leq \sigma \leq 10$
허용 오차	0.001




그림 4.18. 수렴 곡선

Fig. 4.18. Convergence curve




그림 4.19. 추출된 특징점(PCA)
Fig. 4.19. Extracted feature(PCA)




그림 4.20. 추출된 특징점(PCA+LDA)
Fig. 4.20. Extracted feature(PCA+LDA)

그림 4.19는 PCA를 통해 데이터가 축소된 결과로 클래스 2와 3의 데이터들이 어느 정도 가까워 분류에 실패할 수 있음을 볼 수 있다. 그림 4.20은 PCA, LDA 모두 수행한 후 결과로 데이터들의 구별성이 향상된 것을 확인할 수 있다. 이렇게 추출된 특징점을 이용하여 최적화된 파라미터를 사용한 SVM 표적 식별을 수행한 결과는 그림 4.21과 같이 나타났다. 각 클래스 별로 15개의 검증데이터를 사용하여 식별을 수행하였다. 식별 결과를 confusion 매트릭스로 나타낸 것으로, 행렬의 각 열은 실제 클래스를 나타내며 행렬의 각 행은 예측된 클래스를 나타낸다. 행렬의 값은 검증 데이터의 수이다[88]. 예를 들어 그림 4.21에서 좌상단의 검정색으로 표기된 부분은 표적 1의 데이터가 입력되었을 때, 표적 1로 예측된 검증 데이터가 15개라는 의미이다. 즉, 대각원소들은 식별이 성공적으로 이루어진 데이터의 수를 나타내며, 나머지 부분은 잘못 식별된 데이터를 나타낸다. 아래의 결과를 보아, 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다. 또한 잡음의 영향을 분석하기 위하여 검증용 데이터에 화이트 가우시안 잡음을 추가하여 식별 결과를 비교하였다. SNR을 0~40 dB까지 5 dB 간격으로 100번 시행한 성공률을 정리한 결과가 아래의 그림 4.22에 나타나 있다.

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.21. 식별 결과(시뮬레이션)

Fig. 4.21. Identification result (Simulation)

그림 4.22(a)는 12개의 관측각 데이터만 이용하여 얻어진 SAR 영상을 이용한 식별 결과이며, 그림 4.22(b)는 12개의 관측각 데이터에 향상된 OMP만 적용하여 추출된 산란점을 이용한 식별 결과이고, 그림 4.22(c)는 향상된 OMP에 추가로 최적화도 수행하여 추출된 산란점을 이용한 표적 식별 결과이다. 향상된 OMP와 최적화를 수행하여 얻어진 산란점 정보를 이용한 표적 식별 결과가 잡음에 더 강한 것을 확인할 수 있다.




그림 4.22. 잡음에 따른 식별 성공률 (a) SAR (b) 향상된 OMP (c) 향상된 OMP+최적화

Fig. 4.22. Identification success rate according to noise (a) SAR (b) Improved OMP (c) Improved OMP+optimization

4.3.2 측정 실험 결과

실제 측정 데이터를 획득하여 산란점 추출과 표적 식별을 수행하였다. 표 4.4은 실험 환경을 나타낸 것이다. 2개의 X-band용 스탠다드 혼 안테나와 벡터 네트워크 분석기(VNA : Vector Network Analyzer)를 이용하여 신호를 송수신하였으며, 표적의 방위각을 조절하기 위한 로테이터, VNA로부터 신호를 수신하고 로테이터를 제어하기 위한 PC로 실험 환경을 구성하였다[89-91]. 그림 4.23은 레이더 측정 시스템을 나타낸 것으로, 2개의 혼 안테나를 VNA에 연결하였으며, 송신 출력 5dBm, 8~12 GHz 주파수에 801개의 주파수 샘플링으로 측정하고, 측정된 데이터는 PC로 저장된다. 방위각 별로 데이터를 측정하기 위하여 표적을 회전시킬 수 있는 로테이터를 그림 4.24와 같이 구성하였다. 스텝모터 위에 측정하려는 표적을 올려두고 PC를 시리얼 통신을 이용하여 제어하였다. 표적과 안테나 사이의 거리는 4 m로 두었으며, 표적과 안테나의 높이는 1 m이다. 그림 4.25는 측정에 사용된 표적을 나타낸 것으로, 비행기 모델의 축소 모형에 전도성 도료인 실버 페이스트를 도포하였다. 측정 표적들의 크기는 표 4.1의 모델 크기와 동일하다.

표 4.4. 실험 환경

Table 4.4. Experiment environment

안테나	X-band(8~12 GHz)용 Standard Gain 혼 안테나, 20dBi
Vector Network Analyzer	Agilent 사의 8720ES, 송신 출력 5dBm, 8~12 GHz, 801 개 주파수
로테이터	Autonics 사의 A200K-M599-G10 스텝 모터, MD5-HF14 모터 드라이브, PMC-1HS 모션 컨트롤러




그림 4.23. 레이더 측정 시스템

Fig. 4.23. Radar measurement system



그림 4.24. 로테이터

Fig. 4.24. Rotator



(a)



(b)




(c)


그림 4.25. 측정 표적 (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.25. Measured target (a) A-380 (b) Eurofighter (c) F-15


8~12 GHz 주파수에 801개의 주파수 샘플링, 방위각 $-60^{\circ} \sim 60^{\circ}$ (1° 간격)에 대하여 각 표적 별로 측정을 진행하였다. 본 논문에서는 공수 레이더로 다가오는 비행 표적의 경우 앞 부분의 일부 방위각만 측정이 가능할 거라 두고 위와 같이 방위각을 설정하였다. 측정된 데이터를 HRRP로 나타낸 결과가 그림 4.26에 나타나 있다. 그림 4.6의 시뮬레이션 결과와 어느 정도 유사하나, 오차도 어느 정도 존재하는 것을 확인할 수 있다.



(a)



(b)



(c)

그림 4.26. 측정 표적의 HRRP (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.26. HRRP of measured target (a) A-380 (b) Eurofighter (c) F-15


좀 더 정확한 표적의 형태를 보기 위해 방위각 121개의 데이터로 복원된 SAR 영상의 결과가 그림 4.27~4.29에 나타나 있다. 그림 4.7의 시뮬레이션 데이터를 이용한 SAR 영상 결과와 다르게 나타나는 것을 확인할 수 있다. 이는 표적의 정확한 고각과 방위각 설정이 어려우며, 전도성 도료의 도포 상태에 따른 문제로 보이며, 측정된 데이터를 기준으로 표적 식별을 진행하였다.

먼저 산란점 추출 알고리즘을 수행하였다. 12 개의 방위각에 대하여 향상된 OMP 알고리즘을 이용한 산란점 추출을 수행하였는데 그림 4.30에 그 결과가 나타나 있다. 기존의 SAR 영상과 비교해 보면 산란점 정보의 오차가 큰 것을 확인할 수 있다.

획득한 산란점 정보에 혼합 유전 알고리즘 기반의 산란점 추출 알고리즘을 적용하면 그림 4.31의 결과를 획득할 수 있다. SAR 영상에서 크게 보이는 산란점의 정보가 어느 정도 일치하는 것을 확인할 수 있으며, 그림 30에 비해 SAR 영상과의 오차가 많이 줄어들었다.



(a)




(b)

그림 4.27. A-380 (a) 실제 표적 (b) SAR 영상

Fig. 4.27. A-380 (a) Actual target (b) SAR image



(a)




(b)

그림 4.28. Eurofighter (a) 실제 표적 (b) SAR 영상
Fig. 4.28. Eurofighter (a) Actual target (b) SAR image



(a)



(b)

그림 4.29. F-15 (a) 실제 표적 (b) SAR 영상

Fig. 4.29. F-15 (a) Actual target (b) SAR image






그림 4.30. 추출된 산란점 (향상된 OMP, 12개의 관측 방위각) (a) A-380
(b) Eurofighter (c) F-15

Fig. 4.30. Extracted scattering center (Improved OMP, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15






그림 4.31. 추출된 산란점 (향상된 OMP+최적화, 12개의 관측 방위각) (a) A-380 (b) Eurofighter (c) F-15

Fig. 4.31. Extracted scattering center (Improved OMP+optimization, 12 observation azimuth angles) (a) A-380 (b) Eurofighter (c) F-15

측정 데이터로부터 얻은 산란점 정보를 이용하여 표적 식별을 수행하였다. 개별 표적마다 임의의 12 개의 관측 방위각의 수신 신호로부터의 산란점 추출 알고리즘을 30번 수행하고 홀드아웃 검증을 위해 홀수 번째 데이터 15개를 학습용으로 사용하였으며, 짝수 번째 데이터 15개를 검증용으로 사용하였다. 다음으로 PCA, LDA, 커널 함수 파라미터 최적화를 수행한 결과는 다음과 같았다. 유전 알고리즘의 파라미터는 표4.4와 동일하게 설정하였다. 그림 4.32는 수렴 곡선을 나타낸 것으로 13 세대에 수렴하는 것을 볼 수 있다. PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 14, n_{LDA} = 3$ 이 선택되었으며, 커널 파라미터는 $\gamma = 0.8766, \sigma = 7.4804$ 로 설정되었다. 그림 4.33과 4.34는 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

이와 같이 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.35와 같이 나타났다. 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.32. 수렴 곡선(12개의 관측 방위각)

Fig. 4.32. Convergence curve(12 observation azimuth angles)




그림 4.33. 추출된 특징점 (PCA, 12개의 관측 방위각)

Fig. 4.33. Extracted feature (PCA, 12 observation azimuth angles)




그림 4.34. 추출된 특징점 (PCA+LDA, 12개의 관측 방위각)

Fig. 4.34. Extracted feature (PCA+LDA, 12 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.35. 식별 결과(실험, 12개의 관측 방위각)

Fig. 4.35. Identification result(experiment, 12 observation azimuth angles)

선택되는 방위각의 수에 따라서 얻어지는 산란점 정보의 정확도가 달라지므로, 6개의 관측 방위각일 때의 식별 결과를 확인해 보았다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 11, n_{LDA} = 2$ 이 선택되었으며, 커널 파라미터는 $\gamma = 5.30201$ $\sigma = 9.7508$ 로 설정되었다. 그림 4.36과 4.37은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다.

이와 같이 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.38과 같이 나타났다. 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.36. 추출된 특징점(PCA, 6개의 관측 방위각)

Fig. 4.36. Extracted feature(PCA, 6 observation azimuth angles)




그림 4.37. 추출된 특징점(PCA+LDA, 6개의 관측 방위각)

Fig. 4.37. Extracted feature(PCA+LDA, 6 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		

그림 4.38. 식별 결과(실험, 6개의 관측 방위각)

Fig. 4.38. Identification result(experiment, 6 observation azimuth angles)

다음으로 3개의 관측 방위각일 때의 식별 결과를 확인해 보았다.

PCA, LDA 차원 수 최적화를 통해 $n_{PCA} = 20, n_{LDA} = 3$ 이 선택되었으며, 커널 파라미터는 $\gamma = 4.1832$ $\sigma = 2.4408$ 로 설정되었다. 그림 4.39와 4.40은 PCA, LDA를 통한 특징점 압축 결과를 나타낸 것이다. 최적화된 파라미터를 사용하여 SVM 표적 식별을 수행한 결과는 그림 4.41과 같이 나타났다. 방위각의 수가 줄어도 모든 검증용 데이터에 대하여 식별이 성공적으로 이루어지는 것을 확인할 수 있다.




그림 4.39. 추출된 특징점 (PCA, 3개의 관측 방위각)

Fig. 4.39. Extracted feature (PCA, 3 observation azimuth angles)




그림 4.40. 추출된 특징점 (PCA+LDA, 3개의 관측 방위각)


Fig. 4.40. Extracted feature (PCA+LDA, 3 observation azimuth angles)

Output Class	Target1	100% 15	0% 0	0% 0
	Target2	0% 0	100% 15	0% 0
	Target3	0% 0	0% 0	100% 15
		Target1	Target2	Target3
		Input Class		


그림 4.41. 식별 결과(실험, 3개의 관측 방위각)

Fig. 4.41. Identification result(experiment, 3 observation azimuth angles)


SVM 최적화의 성능과 잡음에 대한 영향을 분석하기 위하여 관측 방위각 12, 6, 3일 때의 SNR에 따른 식별 성공률을 비교해 보았다. 그 결과는 아래의 그림 4.42와 그림 4.43과 같다. 그림 4.42는 SVM 최적화 전의 식별 결과이다. $n_{PCA} = 11, n_{LDA} = 11$ 이 선택되었으며, rbf 커널의 파라미터는 $\gamma = 1, \sigma = 1$ 로 설정하였다. 그림 4.43은 SVM 최적화 후의 식별 결과로 PCA, LDA의 차원수와 커널 파라미터는 앞선 방위각 12, 6, 3일 때의 식별에서 선택된 파라미터와 동일하게 설정되었다. SVM 최적화를 한 후의 식별 성능이 월등히 뛰어난 것을 볼 수 있다. 잡음에 대한 성능의 경우, 관측 방위각을 적게 선택할수록 식별 성능이 떨어지지만 SNR 20dB까지는 식별이 잘 이루어지는 것을 확인할 수 있다.



(a)




(b)




(c)

그림 4.42. 잡음에 따른 식별 성공률(SVM 최적화 전) (a) 12개의 관측 방위각 (b) 6개의 관측 방위각 (c) 3개의 관측 방위각


Fig. 4.42. Identification success rate according to noise(before SVM optimization) (a) 12 observation azimuth angles (b) 6 observation azimuth angles (c) 3 observation azimuth angles



(a)



(b)



(c)

그림 4.43. 잡음에 따른 식별 성공률(SVM 최적화 후) (a) 12개의 관측 방위각 (b) 6개의 관측 방위각 (c) 3개의 관측 방위각

Fig. 4.43. Identification success rate according to noise(after SVM optimization) (a) 12 observation azimuth angles (b) 6 observation azimuth angles (c) 3 observation azimuth angles

제 5 장 결론 및 향후 연구 계획

5.1 결론

본 논문에서는 레이더 표적 식별에서 식별 성능에 가장 큰 영향을 주는 특징점 추출 단계에 표적의 산란점 정보를 사용하는 것을 제안하였다. 산란점 정보를 추출하는데 있어, 관측각의 수가 많을수록 보다 정확한 산란점 정보를 획득할 수 있는데, 공대공 표적 식별의 경우, 레이더 표적으로부터 얻을 수 있는 관측각의 데이터는 제한적이다. 그러므로 기존의 데이터보다 더 적은 측정 데이터로도 원본 데이터와 유사한 데이터를 복원할 수 있는 압축 센싱 기법과 최적화 알고리즘을 결합하여 기존의 산란점 추출 방법보다 더 정확하며 연산 속도의 저하를 줄일 수 있는 최적의 산란점 추출 기법을 제안하였다.

본 논문에서는 기존의 CS 알고리즘 중 하나인 OMP 알고리즘에서 변형된 연산 속도가 향상된 OMP 알고리즘을 제시하고 산란점 추출 문제에 적용하여 검증하였다. 기존의 OMP 알고리즘에 비해 약 81%의 연산 시간을 줄일 수 있었으며, 적은 관측각의 데이터만으로도 기존의 BPA 영상과 유사한 산란점 정보를 얻을 수 있었다. 또한, 향상된 OMP로 기존의 OMP에 비해 81.2%의 연산 시간을 줄일 수 있음을 확인하였다. 다음으로 본 논문에서 해결하려는 산란점 추정과 같이 설계 변수가 많은 고차원 최적화 문제의 경우에 강점을 보이는 혼합 유전 알고리즘을 제시하였다. 기존의 유전 알고리즘에 나선형 교차 방식을 선택하여 고차원 문제를 잘 풀 수 있도록 하였으며, 최적 해를 잘 찾으며 수렴 속도를 증가시키기 위해 해 집단을 여러 그룹으로 나누어 각 그룹 별로 다른 교차 방식을 수행하였다. 그에 대한 검증을 위해 여러 시험 함수에 적용하였으며 기존의 알고리즘과의 비교를 수행하여, 기존의 다른 최적화 알고리즘에 비해 고차원 문제를

해결하는데 더 좋은 성능을 보임을 확인하였다. 검증을 위해 산란점 추출 문제에 적용하여 산란점 정보를 잘 추출되는 것을 확인하였다.

앞서 제시한 향상된 OMP 알고리즘과 혼합 유전 알고리즘을 결합하여 최적의 산란점 추출 기법을 제시하였다. 적은 데이터로도 원본 데이터와 유사한 정보를 얻을 수 있는 향상된 OMP 알고리즘을 이용하여 산란점 정보를 추출한 후, 추출된 산란점 정보를 혼합 유전 알고리즘의 초기해로 하여 최적화를 수행하여 수렴속도를 향상시켰다. 기존의 임의의 초기 해를 이용한 최적화에 비해, 64.87%의 연산 시간이 줄어든 것을 확인할 수 있었다. 또한, 향상된 OMP를 이용한 산란점 추출의 경우 임의로 샘플링되는 관측 방위각에 따라 산란점 정보가 제대로 추출되지 못하는 경우가 발생한다. 이러한 문제를 최적화를 통한 보상으로 해결할 수 있다. 최적의 산란점 추출 기법을 검증하기 위하여 3종류의 비행기 표적의 수신 신호를 PO를 이용하여 획득한 후, 실제 이미징 결과에서 보이는 산란점 정보와 비교하였다. 그 결과 산란점 추출이 제대로 이루어짐을 확인하였다.

실제 실험에 적용하기 위하여 금속도료로 도포한 3종류의 모형 비행기를 X-band의 레이더 측정 시스템을 이용하여 측정하였다. 수신된 신호를 최적의 산란점 추출 기법을 적용하여 산란점 정보를 획득하였으며, 획득한 산란점 정보를 특징점으로 두고 표적 식별을 수행하였다. PCA와 LDA를 적용하여 특징점 정보를 압축하고 구별성을 높였으며, SVM 식별기를 이용하여 표적 식별을 수행하였다. 식별 성능의 향상을 위해 PCA, LDA의 차원수와 SVM의 커널 함수를 얻어진 DB에 맞게 최적화하여 식별 성능을 향상시켰다. 그 결과 3종류의 표적을 모두 잘 식별하는 것을 확인하였다.

이와 같이 표적 식별에서 획득할 수 있는 표적의 관측 방위각은 제한적이기에 추출된 산란점 정보의 정확성이 떨어지게 되는데, 이러한 제한적인 상황에서 본 논문에서 제시하는 산란점 추출 기법을 적용하면 보다 정확하게 표적을 식별하는데 도움이 될 것으로 보인다.

5.2 향후 연구 계획

레이더 수신 신호의 경우 표적으로부터 수신되는 신호 외에도 다중 경로에 의한 반사 신호와 클러터에 의한 신호도 함께 수신된다. 수치해석 기법을 활용하거나, 실제 측정으로 다중 경로에 의한 신호를 고려할 수 있지만, 클러터 환경을 모델링하거나 측정하는 것은 어려운 일이다. 본 논문에서는 표적으로 비행기를 선택하여 클러터의 영향이 크지 않았지만, 해상 환경과 같이 클러터의 영향이 큰 상황에서는 클러터의 억제 혹은 클러터 모델링에 대한 추가 연구가 필요하다. 그리고 실제 클러터 환경에서의 측정 및 표적 식별에 대한 연구가 필요할 것으로 보인다.

참고 문헌

- [1] NG, Saab Gripen, “Dynamics of the Saab Group,”
- [2] Gurdal, Armagan, et al, “A High Gain and High Efficiency 15 W X-Band GaN Power Amplifier MMIC,” 2019 European Microwave Conference in Central Europe (EuMCE), IEEE, 2019.
- [3] Anderson, Stuart J, “Target classification, recognition and identification with HF radar,” Proceedings of the NATO Research and Technology Agency. Sensors and Electronics Technology Panel Symposium SET-080 / RSY17 / RFT : “Target identification and recognition using RF systems”, RTO-MP-SET, 2004.
- [4] 최인식, “레이더 표적인식 기술동향 및 전망,” 한국정보통신학회지, vol. 13, no. 2, pp. 34-40.
- [5] Lee, Kun-Chou, Chih-Wei Huang, and Ming-Chung Fang, “Radar target recognition by projected features of frequency-diversity RCS,” Progress In Electromagnetics Research, vol. 81, pp. 121-133, 2008.
- [6] D. Blacknell, H. Griffiths, “Radar Automatic Target Rrecognition(ATR) and Non-Cooperative Target Recognition(NCTR),” The Institution of Engineering and Technology London. UK, 2013.
- [7] C.M. Pilcher and A. Khotanzad, “Maritime ATR using Classifier Combination and High Resolution Range Profiles,” IEEE Trans. on aerospace and electronic systems, vol. 47, no. 4, pp. 2558-2573.
- [8] 최인오, and 박상홍, “다중각도 거리측면도를 이용한 효율적인 차량식별 연구,” 한국정보기술학회논문지, vol. 11, no. 6, pp. 9-16, 2013.
- [9] 최인오, 주문갑 and 박상홍, “거리측면도를 이용한 효율적인 차량식별 요인 및 레이더 규격 연구,” 한국정보기술학회논문지, vol. 10, no. 7, pp. 153-160, 2012.
- [10] Li, Wenchao, Boli Xiong, and Gangyao Kuang, “Target classification and recognition based on micro-Doppler radar signatures.” 2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL), IEEE, 2017.
- [11] Jianxiong, Zhou, et al, “Automatic target recognition of SAR images based on global scattering center model,” IEEE transactions on Geoscience and remote sensing, vol. 49, no. 10, pp. 3713-3729, 2011.
- [12] Liu, Hongwei, et al, “Attributed scattering center extraction algorithm based on sparse representation with dictionary refinement,” IEEE Transactions on Antennas and Propagation, vol. 65, no. 5, pp. 2604-

- 2614, 2017.
- [13] Zhang, Xinzheng, Jianhong Qin, and Guojun Li, "SAR target classification using Bayesian compressive sensing with scattering centers features," *Progress In Electromagnetics Research*, vol. 136, pp. 385–407, 2013.
 - [14] Fu, Yao-wen, Yu-ping Jia, and Zhao-wen Zhuang, "Radar target classification based on one dimensional scattering centers matching," *Dianzi Xuebao(Acta Electronica Sinica)*, vol. 34, no. 3, pp. 404–408, 2006.
 - [15] Koets, Michael A., and Randolph L. Moses, "Feature extraction using attributed scattering center models on SAR imagery," *Algorithms for Synthetic Aperture Radar Imagery VI*, vol. 3721, International Society for Optics and Photonics, 1999.
 - [16] Konovaluk, Maxim, Yury Kuznetsov, and Andrey Baev, "Point scatterers target identification using frequency domain signal processing," *2008 International Radar Symposium, IEEE*, 2008.
 - [17] Karlina, Riafeni, *Compressive Sensing Applied to High Resolution Imaging by Synthetic Aperture Radar*, Ph.D. dissertation, Tohoku University, Japan, Aug. 2013.
 - [18] Jung, Sang-Hoon, et al, "High-resolution millimeter-wave ground-based SAR imaging via compressed sensing," *IEEE Transactions on Magnetism*, vol. 54, no. 3, pp. 1–4, 2017.
 - [19] Chen, Xudong, "Subspace-based optimization method for solving inverse-scattering problems," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 1, pp. 42–49, 2010.
 - [20] Rocca, Paolo, et al, "Evolutionary optimization as applied to inverse scattering problems," *Inverse Problems*, vol. 25, no. 12, p. 123003, 2009.
 - [21] Oliveri, Giacomo, et al, "Multiresolution subspace-based optimization method for inverse scattering problems," *JOSA A*, vol. 28, no. 10, pp. 2057–2069, 2011.
 - [22] Mirjalili, Seyedali, and Andrew Lewis, "The whale optimization algorithm," *Advances in Engineering Software*, vol. 95, pp. 51–67, 2016.
 - [23] Mafarja, Majdi M., and Seyedali Mirjalili, "Hybrid Whale Optimization Algorithm with simulated annealing for feature selection," *Neurocomputing*, vol. 260, pp. 302–312, 2017.
 - [24] Askarzadeh, Alireza, "Bird mating optimizer: an optimization algorithm

- inspired by bird mating strategies,” *Communications in Nonlinear Science and Numerical Simulation*, vol. 19, no. 4, pp. 1213–1228, 2014.
- [25] Askarzadeh, Alireza, and Alireza Rezazadeh, “Extraction of maximum power point in solar cells using bird mating optimizer-based parameters identification approach,” *Solar energy*, vol. 90, pp. 123–133, 2013.
- [26] Frigui, Hichem, and Paul Gader, “Detection and discrimination of land mines in ground-penetrating radar based on edge histogram descriptors and a possibilistic k-nearest neighbor classifier,” *IEEE Transactions on Fuzzy Systems*, vol. 17, no. 1, pp. 185–199, 2008.
- [27] Rish, Irina, “An empirical study of the naive Bayes classifier,” *IJCAI 2001 workshop on empirical methods in artificial intelligence*, vol. 3, no. 22, 2001.
- [28] 강운정, 이종현, 배진호, 이재일, 권지훈, 이노복 and 안미림, “SVM 기반 결정 트리 구조를 이용한 목표물 식별 알고리즘,” *대한전자공학회 학술대회*, pp. 497–500, 2012.
- [29] Walter, G. Carrara, S. Goodman Ron, and M. Majewski Ronald, *Spotlight Synthetic Aperture Radar: Signal Processing Algorithms*, Artech House, 1995.
- [30] Wang, Bu-Chin, *Digital signal processing techniques and applications in radar image processing*, vol. 91, John Wiley & Sons, 2008.
- [31] Briggs, William L., and Van Emden Henson, *The DFT: an owner's manual for the discrete Fourier transform*, Society for Industrial and Applied Mathematics, 1995.
- [32] D. R. Wehner, *High Resolution Radar*, 2nd ed., pp. 197–237, Artech House, Boston, 1995.
- [33] Vidhya, K, “Medical Image Compression using Adaptive Subband Threshold,” *Journal of Electrical Engineering and Technology*, vol. 11, no. 2, pp. 499–507, 2016.
- [34] Jideani, Josiah, and Andrew Wilkinson, “Air-based synthetic aperture sonar tomography using compressive sensing,” *2014 IEEE International Ultrasonics Symposium*, IEEE, 2014.
- [35] Ender, Joachim HG, “On compressive sensing applied to radar,” *Signal Processing*, vol. 90, no. 5, pp. 1402–1414, 2010.
- [36] Candès, Emmanuel J., and Michael B. Wakin, “An introduction to compressive sampling,” *IEEE signal processing magazine*, vol. 25, no. 2, pp. 21–30, 2008.
- [37] Tropp, Joel A., and Anna C. Gilbert, “Signal recovery from random

- measurements via orthogonal matching pursuit,” *IEEE Transactions on information theory*, vol. 53, no. 12, pp. 4655–4666, Dec. 2007.
- [38] Needell, Deanna, and Joel A. Tropp, “CoSaMP: Iterative signal recovery from incomplete and inaccurate samples,” *Applied and computational harmonic analysis*, vol. 26, no. 3, pp. 301–321, 2009.
- [39] Tipping, Michael E, “The relevance vector machine,” *Advances in neural information processing systems*, 2000.
- [40] Hughes, Thomas JR, Leopoldo P. Franca, and Gregory M. Hulbert, “A new finite element formulation for computational fluid dynamics: VIII. The Galerkin/least-squares method for advective-diffusive equations,” *Computer methods in applied mechanics and engineering*, vol. 73, no. 2, pp. 173–189, 1989.
- [41] Nussbaumer, Henri J, “The fast Fourier transform,” *Fast Fourier Transform and Convolution Algorithms*, Springer, Berlin, Heidelberg, pp. 80–111, 1981.
- [42] Yigit, Enes, et al, “Short-range ground-based synthetic aperture radar imaging: performance comparison between frequency-wavenumber migration and back-projection algorithms,” *Journal of Applied Remote Sensing*, vol. 7, no. 1, pp. 073483–073483, 2013.
- [43] Yegulalp, Ali F, “Fast backprojection algorithm for synthetic aperture radar,” *Proceedings of the 1999 IEEE Radar Conference, Radar into the Next Millennium (Cat. No. 99CH36249)*, IEEE, 1999.
- [44] Nocedal, Jorge, and Stephen J. Wright, “Conjugate gradient methods,” *Numerical optimization*, pp. 101–134, 2006.
- [45] Battiti, Roberto, “First- and second-order methods for learning: between steepest descent and Newton's method,” *Neural computation* vol. 4, no. 2, pp. 141–166, 1992.
- [46] Ruder, Sebastian, “An overview of gradient descent optimization algorithms,” *arXiv preprint arXiv:1609.04747*, 2016.
- [47] Weicker, Karsten, and Nicole Weicker, “On evolution strategy optimization in dynamic environments,” *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, vol. 3, IEEE, 1999.
- [48] Whitley, Darrell, “A genetic algorithm tutorial,” *Statistics and computing*, vol. 4, no. 2, pp. 65–85, 1994.
- [49] Gudla, Pradeep Kumar, and Ranjan Ganguli, “An automated hybrid genetic-conjugate gradient algorithm for multimodal optimization problems,” *Applied Mathematics and Computation*, vol. 167, no. 2, pp.

- 1457–1474, 2005.
- [50] Michael, W., and J. N. Siddall, “The optimization problem with optimal tolerance assignment and full acceptance,” pp. 842–848, 1981.
 - [51] Kwon, Hyuk–Sung, Jong–Suk Ro, and Hyun–Kyo Jung, “A novel social insect optimization algorithm for the optimal design of an interior permanent magnet synchronous machine,” *IEEE Transactions on Magnetics*, vol. 54, no. 12, pp. 1–6, 2018
 - [52] Molga, Marcin, and Czesław Smutnicki, “Test functions for optimization needs,” *Test functions for optimization needs*, vol. 101, 2005.
 - [53] Giusfredi, Giovanni, *Physical optics: concepts, optical elements, and techniques*, Springer, 2019.
 - [54] B. Li, G.J. Zhang and Y. Wang, “Application of MoM–PO Hybrid Technique in Complex Target High Resolution Imaging Simulation,” *IET International Radar Conference*, 2009.
 - [55] Jakowatz, Charles VJ, et al. *Spotlight–mode synthetic aperture radar: a signal processing approach: a signal processing approach*, Springer Science & Business Media, 2012.
 - [56] Beckmann, Matthias, and Armin Iske, “Error estimates for filtered back projection.” *2015 International Conference on Sampling Theory and Applications (SampTA)*, IEEE, 2015.
 - [57] Shlens, Jonathon, “A tutorial on principal component analysis,” *arXiv preprint arXiv:1404.1100*, 2014.
 - [58] Jolliffe, Ian T., and Jorge Cadima, “Principal component analysis: a review and recent developments,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 374.2065, p. 20150202, 2016.
 - [59] Tharwat, Alaa, et al, “Linear discriminant analysis: A detailed tutorial,” *AI communications*, vol. 30, no. 2, pp. 169–190, 2017.
 - [60] Lee, K–C., and J–S. Ou, “Radar target recognition by using linear discriminant algorithm on angular–diversity RCS,” *Journal of Electromagnetic Waves and Applications*, vol. 21, no. 14, pp. 2033–2048, 2007.
 - [61] Barnouti, Nawaf Hazim, et al, “Face Detection and Recognition Using Viola–Jones with PCA–LDA and Square Euclidean Distance,” *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 7, no. 5, pp. 371–377, 2016.
 - [62] Gou, Jianping, et al, “A new distance–weighted k–nearest neighbor

- classifier,” *J. Inf. Comput. Sci*, vol. 9, no. 6, pp. 1429–1436, 2012
- [63] Sohail, Abu Sayeed Md, and Prabir Bhattacharya, “Classification of facial expressions using k-nearest neighbor classifier,” *International Conference on Computer Vision/Computer Graphics Collaboration Techniques and Applications*. Springer, Berlin, Heidelberg, 2007.
- [64] Duda, R. O., P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd edition, John Wiley & Sons Inc., 2001.
- [65] Sebe, Nicu, et al, “Emotion recognition using a cauchy naive bayes classifier,” *Object recognition supported by user interaction for service robots*, vol. 1, IEEE, 2002.
- [66] Mukherjee, Saurabh, and Neelam Sharma, “Intrusion detection using naive Bayes classifier with feature reduction,” *Procedia Technology*, vol. 4, pp. 119–128, 2012.
- [67] LI, Jing-hua, Jia-dong XU, and Hong-juan LI, “Research on Helicopter Target Identification based on Support Vector Machine [J],” *Fire Control and Command Control*, vol. 1, 2008.
- [68] Kent, S., N. G. Kasapoglu, and M. Kartal, “Radar target classification based on support vector machines and high resolution range profiles,” *2008 IEEE Radar Conference*. IEEE, 2008.
- [69] Kim, Youngwook, and Hao Ling, “Human activity classification based on micro-Doppler signatures using a support vector machine,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 5, pp. 1328–1337, 2009.
- [70] Liu, Liang, et al, “Fall detection using doppler radar and classifier fusion,” *Proceedings of 2012 IEEE-EMBS International Conference on Biomedical and Health Informatics*, IEEE, 2012.
- [71] Suykens, Johan AK, and Joos Vandewalle, “Least squares support vector machine classifiers,” *Neural processing letters*, vol. 9, no. 3, pp. 293–300, 1999.
- [72] Cauwenberghs, Gert, and Tomaso Poggio, “Incremental and decremental support vector machine learning,” *Advances in neural information processing systems*, 2001.
- [73] Bufler, Travis D., and Ram M. Narayanan, “Radar classification of indoor targets using support vector machines,” *IET Radar, Sonar & Navigation*, vol. 10, no. 8, pp. 1468–1476, 2016.
- [74] 이강인, 다중 HRRP 기반 표적 산란점 추정 및 식별 연구, 공학박사 학위논문, 광운대학교, 2018.
- [75] Nguyen, Loc, “Tutorial on support vector machine,” *Applied and*

- Computational Mathematics 6.4–1 pp. 1–15, 2017.
- [76] Bertsekas, Dimitri P, Constrained optimization and Lagrange multiplier methods, Academic press, 2014.
 - [77] Best, Michael J, Quadratic programming with computer programs, CRC Press, 2017.
 - [78] Doucet, Jean–Pierre, et al, “Nonlinear SVM approaches to QSPR /QSAR studies and drug design,” Current Computer–Aided Drug Design vol. 3, no. 4, pp. 263–289, 2007.
 - [79] Wang, Lipo, Support vector machines: theory and applications. vol. 177, Springer Science & Business Media, 2005.
 - [80] Hofmann, Martin, “Support vector machines–kernels and the kernel trick,” Notes, vol. 26, no. 3, 2006.
 - [81] Kung, Sun Yuan, Kernel methods and machine learning, Cambridge University Press, 2014.
 - [82] Prajapati, Gend Lal, and Arti Patle, “On performing classification using SVM with radial basis and polynomial kernel functions,” 2010 3rd International Conference on Emerging Trends in Engineering and Technology, IEEE, 2010.
 - [83] Amari, Shun–ichi, and Si Wu, “Improving support vector machine classifiers by modifying kernel functions,” Neural Networks, vol. 12, no. 6, pp. 783–789, 1999.
 - [84] Camps–Valls, Gustavo, et al, “Fuzzy sigmoid kernel for support vector classifiers,” Neurocomputing, vol. 62, pp. 501–506, 2004.
 - [85] Wu, Chih–Hung, Gwo–Hshiung Tzeng, and Rong–Ho Lin, “A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression,” Expert Systems with Applications, vol. 36, no. 3, pp. 4725–4735, 2009.
 - [86] Yang, Liu, et al. "Comparison research of single kernel and multi–kernel relevance vector machine." Computer Engineering, vol. 36, no. 12, pp. 195–197, 2010.
 - [87] Oxford, Raquel M., and Larry G. Daniel, “Basic Cross–Validation: Using the “Holdout” Method To Assess the Generalizability of Results,” Research in the Schools, vol. 8, no. 1, pp. 83–89, 2001.
 - [88] Visa, Sofia, et al, “Confusion Matrix–based Feature Selection,” MAICS, vol. 710, pp. 120–127, 2011.
 - [89] Burki, Jehanzeb, Touseef Ali, and Shahzad Arshad, “Vector network analyzer (VNA) based synthetic aperture radar (SAR) imaging,” INMIC, IEEE, 2013.

- [90] Caliskan, Alper, et al, “24 GHz short range radar system measurements for synthetic aperture radar imaging,” 2017 IEEE Microwaves, Radar and Remote Sensing Symposium (MRRS), IEEE, 2017.
- [91] Lee, Hoonyol, Younghun Ji, and Hyangsun Han, “Experiments on a ground-based tomographic synthetic aperture radar,” Remote Sensing vol. 8, no. 8, pp. 667, 2016.

Abstract

Optimal Scattering Center Extraction and Identification in Radar Target

Sang-Hoon Jung

Dept. of Electrical and Computer Engineering

The Graduate School

Seoul National University

In this paper, it is proposed to use the scattering center information of the target as a feature used in the feature extraction step that has the greatest influence on the identification performance in radar target identification. A technique combining a compressive sensing (CS) that can reconstruct data similar to the original data in case of limited measurement like air to air detection, and a high-dimensional optimization algorithm is proposed. This technique is more accurate than the conventional scattering center extraction method and can reduce a decrease in computation speed. To verify this technique, the identification using a raw data obtained through the numerical analysis method was performed. And verification was also conducted through actual measurement experiment.

First, the acquisition process and modeling of the received radar signal used for target identification was explained, and then the specific principles of the CS algorithm and the high-dimensional optimization algorithm that are the basis of the optimal scattering

center extraction algorithm presented in this paper were described.

A CS algorithm with improved computational speed, which is modified from the orthogonal matching pursuit (OMP) algorithm, which is one of the conventional CS algorithms, is presented and verified by applying it to a simple scattering center extraction problem. It was confirmed that the same scattering center information was extracted while reducing the computational time of 81.2% than the conventional OMP. Next, in this paper, we proposed a hybrid genetic algorithm that shows strength in solving high-dimensional optimization problems with many design variables, such as extraction of scattering center. Spiral crossover was selected to solve high-dimensional problems well, and in order to find an optimal solution and to increase the convergence speed, solution groups were divided into several groups, and different crossover methods were performed for each group. To verify the algorithm, it was applied to several test functions and scattering center extraction problem and compared with the conventional optimization algorithm.

In order to extract the optimal scattering point, the improved OMP algorithm and the hybrid genetic algorithm presented above were combined. First, scattering centers were extracted by applying an improved OMP algorithm to the received radar signal. More accurate scattering center information was extracted by applying the hybrid genetic algorithm using the extracted scattering center as an initial value. As a result, the increase in computational time, which is a disadvantage of the hybrid genetic algorithm, was reduced by 64.87%.

Target identification was performed using the obtained scattering center information. As an identifier, a support vector machine

(SVM) capable of optimization was used. For verification, the optimal scattering center extraction technique is applied to the simulation data and actual measurement data, and identification is performed with the SVM identifier. As a result, it was confirmed that it showed a high identification success rate even with small measurement data such as three observation azimuth angles, and it was confirmed that it was successfully identified even in a noise environment of SNR 20 dB.

The observation angle of the target that can be obtained in the identification performance is limited, and the accuracy of the acquired scattering center information is also reduced. In this limited situation, applying proposed algorithm will help to more accurately identify the target.

Keywords : Compressive Sensing, Extraction of Scattering Center, Feature Extraction, High-dimensional Optimization, Support Vector Machine, Target Identification.

Student Number : 2014-22578